

Leonardo de Carvalho Vidal
Gilmar Gonçalves de Oliveira
Juliana Ribas Monteiro
Wallace Pereira Neves dos Reis
(Orgs.)

TECNOLOGIAS EMERGENTES EM ENGENHARIA

CONVERGÊNCIA ENTRE AUTOMAÇÃO,
ROBÓTICA, METROLOGIA E ENERGIA



científica digital



CIENTÍFICA DIGITAL EDITORIAL LTDA

Barueri - São Paulo - Brasil
www.cientificadigital.org - contato@cientificadigital.org

Diagramação e Arte	Edição © 2025 Científica Digital
Diego Santos	Texto © 2025 Os Autores
Diogo Lima	1ª Edição - 2025
Imagens da Capa	Acesso Livre - Open Access
Adobe Stock - 2025	

© COPYRIGHT - TODOS OS DIREITOS RESERVADOS. A editora detém os direitos autorais sobre a edição e o projeto gráfico, enquanto os autores mantêm os direitos autorais de seus respectivos textos. Esta obra está licenciada sob a Licença Creative Commons Atribuição 4.0 Internacional, permitindo o download e compartilhamento integral ou parcial, desde que a fonte seja devidamente citada e os créditos atribuídos aos autores. É obrigatório que a obra permaneça em formato de Acesso Livre (Open Access), sem qualquer alteração. A catalogação em plataformas de acesso restrito ou com fins comerciais é estritamente proibida.



Dados Internacionais de Catalogação na Publicação (CIP)

T255

Tecnologias emergentes em engenharia: convergência entre automação, robótica, metrologia e energia / Organização de Leonardo de Carvalho Vidal, Gilmar Gonçalves de Oliveira, Juliana Ribas Monteiro, et al. – Barueri-SP: Científica Digital, 2025.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui Bibliografia

ISBN 978-65-83998-26-2

DOI 10.37885/978-65-83998-26-2

1. Engenharia. I. Vidal, Leonardo de Carvalho (Organizador). II. Oliveira, Gilmar Gonçalves de (Organizador). III. Monteiro, Juliana Ribas (Organizadora). IV. Título.

CDD 620

Elaborado por Janaína Ramos – CRB-8/9166

Índice para catálogo sistemático:

I. Engenharia

E-BOOK

ACESSO LIVRE ON LINE - IMPRESSÃO PROIBIDA

2025

Leonardo de Carvalho Vidal
Gilmar Gonçalves de Oliveira
Juliana Ribas Monteiro
Wallace Pereira Neves dos Reis
(Orgs.)

Tecnologias Emergentes em Engenharia:

**Convergência entre Automação, Robótica,
Metrologia e Energia**

1ª EDIÇÃO



científica digital

2025 - BARUERI - SP

CONSELHO EDITORIAL

Prof. Dr. André Cutrim Carvalho
Prof. Dr. Antônio Marcos Mota Miranda
Prof^a. Ma. Auristela Correa Castro
Prof. Dr. Carlos Alberto Martins Cordeiro
Prof. Dr. Carlos Alexandre Oelke
Prof^a. Dra. Caroline Nóbrega de Almeida
Prof^a. Dra. Clara Mockdece Neves
Prof^a. Dra. Claudia Maria Rinhel-Silva
Prof^a. Dra. Clecia Simone Gonçalves Rosa Pacheco
Prof. Dr. Cristiano Marins
Prof^a. Dra. Cristina Berger Fadel
Prof. Dr. Daniel Luciano Gevehr
Prof. Dr. Diogo da Silva Cardoso
Prof. Dr. Ernane Rosa Martins
Prof. Dr. Everaldo dos Santos Mendes
Prof. Dr. Fabricio Gomes Gonçalves
Prof^a. Dra. Fernanda Rezende
Prof. Dr. Flávio Aparecido de Almeida
Prof^a. Dra. Francine Náthalie Ferraresi Queluz
Prof^a. Dra. Geuciane Felipe Guerim Fernandes
Prof. Dr. Humberto Costa

Prof. Dr. Joachin Melo Azevedo Neto
Prof. Dr. Jónata Ferreira de Moura
Prof. Dr. José Aderval Aragão
Prof. Me. Julianno Pizzano Ayoub
Prof. Dr. Leonardo Augusto Couto Finelli
Prof. Dr. Luiz Gonzaga Lapa Junior
Prof. Me. Marcelo da Fonseca Ferreira da Silva
Prof^a. Dra. Maria Cristina Zago
Prof^a. Dra. Maria Otília Zangão
Prof. Dr. Mário Henrique Gomes
Prof. Dr. Marcus Fernando da Silva Praxedes
Prof. Dr. Nelson J. Almeida
Prof. Dr. Pedro Afonso Cortez
Prof. Dr. Reinaldo Pacheco dos Santos
Prof. Dr. Rogério de Melo Grillo
Prof^a. Dra. Rosenery Pimentel Nascimento
Prof. Dr. Rossano Sartori Dal Molin
Prof. Me. Silvio Almeida Junior
Prof^a. Dra. Thays Zigante Furlan Ribeiro
Prof. Dr. Wescley Viana Evangelista
Prof. Dr. Willian Carboni Viana
Prof. Dr. Willian Douglas Guilherme

Acesse a lista completa dos Membros do Conselho Editorial em www.editoracientifica.com.br/conselho

Parecer e revisão por pares

Os textos que compõem esta obra passaram por avaliação do Conselho Editorial e revisão por pares externos (*Peer Review*), recebendo a devida recomendação para publicação.

Nota: Esta obra é fruto de um processo colaborativo, configurando-se como uma coletânea na qual os direitos autorais permanecem resguardados para os respectivos autores. Alguns capítulos podem ter origem em trabalhos anteriormente apresentados em eventos acadêmicos; no entanto, os autores foram orientados a adotar o devido rigor na prevenção do autoplágio. A responsabilidade pelo conteúdo de cada capítulo, assim como pela originalidade e integridade das informações publicadas, é inteiramente dos respectivos autores e autoras. O conteúdo da obra não reflete, necessariamente, a opinião da editora, dos organizadores ou dos membros do conselho editorial.

APRESENTAÇÃO

Vivemos em uma era de transformação acelerada, onde as fronteiras entre as disciplinas tradicionais da engenharia se tornam cada vez mais tênues. Por décadas, a **Automação**, a **Robótica**, a **Metrologia** e a **Energia** foram tratadas como campos de estudo e aplicação distintos. No entanto, a complexidade dos desafios modernos — desde a busca por maior eficiência e produtividade até a imperativa necessidade de sustentabilidade — nos força a enxergar essas áreas não como ilhas isoladas, mas como continentes conectados.

Este livro surge da convicção de que o futuro da engenharia reside na **convergência**. Ele é o resultado da colaboração de diversas vozes e perspectivas, unidos por um interesse comum em compreender e aplicar o potencial das tecnologias emergentes. Cada capítulo, fruto de cuidadosa pesquisa e análise, contribui para um panorama mais amplo de como essas disciplinas se entrelaçam.. O que acontece quando um sistema robótico não é apenas programado para uma tarefa, mas se torna autônomo, otimizando seu consumo de energia com base em dados de metrologia em tempo real? Ou quando a precisão de um sensor, antes usada para inspeção, agora guia um processo de manufatura inteiramente automatizado e energeticamente eficiente?

Ao longo destas páginas, exploraremos como a sinergia entre esses pilares está criando as **fábricas inteligentes**, as **redes elétricas do futuro** e os **sistemas de produção mais resilientes**. Acreditamos que a próxima geração de engenheiros, inventores e líderes será definida pela sua capacidade de integrar essas tecnologias de forma holística.

Que este trabalho sirva como um guia e uma inspiração para todos aqueles que buscam não apenas acompanhar a mudança, mas ser os arquitetos do nosso amanhã. O futuro da engenharia não é sobre uma única tecnologia, mas sobre a orquestração de todas elas, por meio do conhecimento compartilhado e da colaboração de diversas perspectivas..

Leonardo de Carvalho Vidal

Gilmar Gonçalves de Oliveira

Juliana Ribas Monteiro

Wallace Pereira Neves dos Reis

SUMÁRIO

Capítulo 01

FAZENDAS INTELIGENTES: UTILIZANDO INTELIGÊNCIA ARTIFICIAL PARA PREVISIBILIDADE DA PRODUÇÃO AGRÍCOLA

Gabriel da Silva Franck; Leonardo de Carvalho Vidal; Pedro Mazarello de Souza

doi 10.37885/250519382 9

Capítulo 02

***MACHINE LEARNING* NA SIDERURGIA: REVISÃO SISTEMÁTICA DA APLICAÇÃO DE IA NA MANUTENÇÃO PREDITIVA EM LAMINADORES DE TIRAS À QUENTE AÇOS PLANOS**

Antonio Carlos Pimentel Junior; Leonardo de Carvalho Vidal

doi 10.37885/250519387 26

Capítulo 03

MODELAGEM E CONTROLE PARA ESTABILIZAÇÃO DE UM QUADRIROTOR COM UM GRAU DE LIBERDADE

Pedro Henrique Col Carvalho; Leandro Castilho Brolin; Flávio Luiz Rossini; Marcelo Nanni

doi 10.37885/250519390 44

Capítulo 04

ESTUDO DE CASO COM MODELAGEM DA CINEMÁTICA DIRETA E INVERSA ANALÍTICA DO ROBÔ ABB IRB 1010 E VALIDAÇÃO VIA SIMULAÇÃO

Gabriel Pitondo Rossini; Otávio Amaro de Paula dos Santos; Flávio Luiz Rossini

doi 10.37885/250619554 69

Capítulo 05

DESENVOLVIMENTO DE SISTEMA EMBARCADO COM REDE NEURAL PARA DETECÇÃO DE SUJEIRA EM PAINÉIS SOLARES

Rodrigo Afonso de Souza; Gilmar Gonçalves de Oliveira

doi 10.37885/250719749 96

Capítulo 06**INTEGRAÇÃO MECATRÔNICA ENTRE SCANNERS E EIXOS LINEARES PARA PROCESSAMENTO A LASER**

Claudio Abilio da Silveira; Milton Pereira; Walter Lindolfo Weingaertner

doi 10.37885/250719753 128**Capítulo 07****MODELAGEM E PREVISÃO DO TEMPO DE DESCARGA DE BATERIAS DE LÍCIO: UMA ANÁLISE NO CONTEXTO DA INTELIGÊNCIA ARTIFICIAL**

Natan Cerqueira Amorim; Leonardo de Carvalho Vidal; Claudeci Fonseca Medeiros

doi 10.37885/250819878 147**Capítulo 08****CONTROLE DISTRIBUÍDO EM SUBESTAÇÕES DIGITAIS COM IEC 61850: O FUTURO DAS REDES INTELIGENTES**

Pedro Mazarello de Souza; Leonardo de Carvalho Vidal

doi 10.37885/250819879 168**Capítulo 09****ANÁLISE DA QUALIDADE DA ÁGUA UTILIZANDO UM MODELO *FUZZY***

Leiziane Aparecida Tavares Pereira; Juliana Ribas Monteiro; Leonardo de Carvalho Vidal

doi 10.37885/250819882 183**Capítulo 10****REVISÃO E COMPARAÇÃO DE ESTRATÉGIAS DE CONTROLE - CONTROLE CLÁSSICO, MODERNO, ADAPTATIVO, NÃO LINEAR E INTELIGENTE**

Wesley Rossi Pimenta; Leonardo de Carvalho Vidal

doi 10.37885/250819958 207

Capítulo 11

**IDENTIFICAÇÃO DE UM PROCESSO COM CARACTERÍSTICA NÃO LINEAR E
COMPARAÇÕES DE DESEMPENHO EM RELAÇÃO A UM MODELO NARMAX E
UM MODELO COM RNAS**

Jorge Lucas Torres Cassaro; Juliana Ribas Monteiro

 10.37885/250819955 **226**

SOBRE OS ORGANIZADORES **246**

ÍNDICE REMISSIVO **248**

FAZENDAS INTELIGENTES: UTILIZANDO INTELIGÊNCIA ARTIFICIAL PARA PREVISIBILIDADE DA PRODUÇÃO AGRÍCOLA

Gabriel da Silva Franck
Instituto Federal do Rio de Janeiro (IFRJ)

Leonardo de Carvalho Vidal
Instituto Federal do Rio de Janeiro (IFRJ)

Pedro Mazarello de Souza
Universidade Federal de Itajubá (UNIFEI)

RESUMO

Objetivo: A previsibilidade da produção agrícola representa um elemento crítico para a eficiência operacional e sustentabilidade econômica no agronegócio. Este trabalho apresenta o desenvolvimento de um aplicativo baseado em algoritmos de análise preditiva, codificados em Python, com o propósito de estimar investimentos, custos operacionais e retorno financeiro para diferentes culturas agrícolas. Os resultados foram validados por técnicos especializados da Emater-RJ (Empresa de Assistência Técnica e Extensão Rural), garantindo a confiabilidade das projeções. O sistema utiliza bancos de dados públicos da Embrapa (Empresa Brasileira de Pesquisa Agropecuária), combinados com parâmetros agrônômicos como tipo de solo e área cultivada, para gerar recomendações personalizadas, incluindo indicadores de rentabilidade e sustentabilidade ambiental. **Métodos:** O sistema foi desenvolvido em Python, empregando técnicas de processamento numérico para correlacionar dados climáticos e de solo com variáveis econômicas, como custos de insumos e preços de mercado. As simulações foram validadas por técnicos da Emater-RJ e Emater-SP, com base em dados reais da cafeicultura na região do Sul Fluminense. O modelo considera recomendações técnicas para agricultura, como necessidade de adubação e irrigação, custos fixos e variáveis, incluindo mudas, mão de obra e equipamentos, além de realizar análise de sensibilidade para variações de produtividade e calcular métricas de sustentabilidade, como a pegada de carbono equivalente por saca produzida. **Resultados:** Em um estudo de caso envolvendo uma propriedade de 1 hectare de cultivo do café em Volta Redonda, em solo do tipo Espodosolos, o aplicativo gerou projeções com retorno sobre investimento de 72,76%, correspondendo a um investimento total de R\$ 79.880,00 e receita projetada de R\$ 138.000,00. A produtividade foi estimada em 3.600 kg de grãos de café por hectare, equivalente a 60 sacas por hectare, com margem de lucro bruta de 42,12%. O ponto de equilíbrio foi alcançado com a produção de 34,73 sacas por hectare, enquanto a pegada de carbono ficou em 0,02 toneladas de dióxido de carbono equivalente por saca. A análise de sensibilidade demonstrou a robustez do modelo, com variações de lucratividade entre R\$ 30.520,00 por hectare na análise pessimista e R\$ 85.720,00 por hectare no cenário otimista.

Palavras-chave: Previsibilidade; produção; viabilidade de investimento; sustentabilidade; aplicação.

INTRODUÇÃO

A importância das fazendas inteligentes é multifacetada. O conceito permite otimizar o uso de recursos, como água, fertilizantes e pesticidas, reduzindo desperdícios e custos operacionais, sendo crucial em um cenário de crescente escassez de recursos naturais e pressão ambiental. As fazendas inteligentes contribuem para a sustentabilidade do setor agrícola, minimizando os impactos ambientais negativos possibilitando a execução de boas práticas agrícolas mais precisas e menos invasivas.

A implementação de métodos modernos viabiliza a economia das fazendas, pois as tecnologias avançadas aumentam a produtividade e a qualidade dos produtos agrícolas, tornando-as mais competitivas no mercado global. A implementação de fazendas inteligentes depende de várias tecnologias de ponta, as quais, o *Big Data* complementa a definição de IoT e a IA permitindo o armazenamento e análise de grandes volumes de dados históricos e em tempo real, facilitando a identificação de padrões e tendências que podem não ser evidentes em dados menores ou menos complexos. A análise de *Big Data* ajuda os agricultores a tomar decisões mais informadas e estratégicas, melhorando a eficiência e a produtividade geral da fazenda. A combinação dessas tecnologias cria um ecossistema interconectado que transforma a gestão agrícola, proporcionando uma abordagem precisa.

MÉTODOS

Previsibilidade de produção e viabilidade de investimento com o uso de algoritmos desenvolvidos em Python e utilização de chave A.P.I com Chat GPT.

O sistema desenvolvido utiliza uma abordagem híbrida que combina processamento local de dados com inteligência artificial generativa através de chave API *OpenAI*. A implementação foi realizada em Python, separadas em quatro classes principais, cada uma responsável por um conjunto específico de funcionalidades, seguindo os princípios de coesão e baixo acoplamento. A arquitetura adotada permite uma clara separação de responsabilidades, facilitando a manutenção e futuras expansões do sistema.

A classe *Config* atua como centralizadora dos parâmetros globais do sistema, implementando um padrão de configuração unificada. Ela gerencia não apenas o diretório padrão para armazenamento de dados e o tempo de cache, mas também realiza a obtenção segura da chave de API através de variáveis de ambiente, seguindo as melhores práticas de segurança da informação. Essa abordagem evita o *hardcoding* de credenciais no código-fonte e permite diferentes configurações entre ambientes de desenvolvimento e produção. A classe foi projetada com métodos de classe (*classmethod*) para permitir acesso fácil às configurações sem necessidade de instalação, seguindo o padrão *Singleton* adaptado para Python.

Figura 1 - Codificação da Classe *Config*.

```
class Config:
    DATA_DIR = "data"
    HISTORY_FILE = "history.json"
    OPENAI_API_KEY = os.getenv("OPENAI_API_KEY", "")
    CACHE_TIMEOUT = 86400 # 24 horas em segundos

    @classmethod
    def get_data_path(cls, filename):
        return os.path.join(cls.DATA_DIR, filename)
```

A classe *DataService* encapsula toda a lógica de persistência de dados, atuando como uma camada de abstração sobre o sistema de arquivos. Ela implementa operações *CRUD* completas para arquivos *JSON*, incluindo tratamento robusto de exceções para casos de arquivos corrompidos ou permissões inadequadas. Os métodos estáticos foram escolhidos para evitar estado desnecessário na classe, já que todas as operações são puramente funcionais. A classe utiliza *encoding* UTF-8 explicitamente em todas as operações de arquivo, garantindo compatibilidade com caracteres especiais e acentuação. Além disso, implementa automaticamente a criação de diretórios quando necessário, prevenindo erros comuns de "diretório não encontrado".

Figura 2 - Codificação da Classe *DataService*.

```
class DataService:
    @staticmethod
    def load_json(filename):
        path = Config.get_data_path(filename)
        try:
            with open(path, 'r', encoding='utf-8') as f:
                return json.load(f)
        except:
            return {}

    @staticmethod
    def save_json(data, filename):
        os.makedirs(Config.DATA_DIR, exist_ok=True)
        path = Config.get_data_path(filename)
        with open(path, 'w', encoding='utf-8') as f:
            json.dump(data, f, ensure_ascii=False, indent=2)

    @staticmethod
    def add_history_entry(entry):
        history = DataService.load_json(Config.HISTORY_FILE) or []
        history.append(entry)
        DataService.save_json(history, Config.HISTORY_FILE)
```

A classe *AIService* representa o núcleo de inteligência artificial do sistema, encapsulando toda a complexidade da comunicação com APIs externas. Ela implementa um padrão de *retry* automático para falhas transitórias de rede e inclui verificações detalhadas de conectividade antes de tentar chamadas à API. O método principal, *get_ai_recommendation*, foi projetado para ser altamente configurável, permitindo ajustes finos nos parâmetros da chamada à API OpenAI, como temperatura e formato de resposta. A classe também implementa um sistema de cache básico para evitar chamadas redundantes à API com os mesmos parâmetros, melhorando a eficiência e reduzindo custos operacionais.

A classe *AgroTechApp* é responsável pela interface com o usuário final, implementando o padrão *Model-View-Controller* (MVC) de forma adaptada para aplicações *desktop*. Utilizando a biblioteca *CustomTkinter*, ela cria uma interface moderna e responsiva, com componentes dinâmicos que se adaptam aos dados carregados. A classe é cuidadosamente estruturada em métodos especializados para cada parte da interface, como *create_header* para o cabeçalho e *setup_ui* para a construção da interface principal. A implementação inclui tratamento avançado de eventos, validação de entrada em tempo real e atualização dinâmica dos componentes visuais. A classe também gerencia o estado da aplicação,

coordenando as interações entre as demais classes do sistema para fornecer uma experiência de usuário fluida e consistente.

Cada classe foi projetada com testes unitários abrangentes, cobrindo tanto os casos de uso normais quanto as situações de erro. A arquitetura modular permite que componentes individuais sejam atualizados ou substituídos com impacto mínimo no restante do sistema, seguindo o princípio da responsabilidade única. A documentação detalhada dos métodos e atributos, incluindo tipos de retorno e exceções possíveis, foi incorporada diretamente no código-fonte através de *docstrings* seguindo o padrão *Google Style*.

A comunicação com a API *OpenAI* é realizada através de requisições *HTTP POST*, utilizando o modelo GPT-4 Turbo. O sistema envia *prompts* estruturados contendo todos os parâmetros agrônômicos necessários, conforme demonstra a **figura 3**.

Figura 3 - Codificação de comunicação com o Chat GPT.

```
headers = {
    "Authorization": f"Bearer {Config.OPENAI_API_KEY}",
    "Content-Type": "application/json"
}
payload = {
    "model": "gpt-4-turbo",
    "messages": [{
        "role": "user",
        "content": prompt
    }],
    "temperature": 0.7,
    "response_format": {"type": "json_object"}
}
response = requests.post("https://api.openai.com/v1/chat/completions",
                        headers=headers,
                        json=payload)
```

Os parâmetros incluídos no *prompt* são validados contra um banco de dados local construído com base nas recomendações técnicas da EMATER-RJ, garantindo que apenas valores dentro de faixas realistas sejam enviados à API (EMATER-RJ, 2022).

Quanto offline, o sistema utiliza um banco de dados local contendo parâmetros técnicos validados por engenheiros agrônomos da EMATER-RJ.

O cálculo das recomendações offline é realizado através do método *get local recommendation*, que aplica fórmulas de proporcionalidade baseadas na área cultivada.

A validação do sistema foi conduzida mediante abordagem metodológica multinível, fundamentada em princípios consagrados da engenharia de software e agronomia digital. O processo adotou um *framework tripartite* que integra, uma validação técnica baseada no modelo de verificação cruzada proposta por Kitchenham *et al.* (2010), comparando sistematicamente as saídas do sistema com padrões de referência estabelecidos na literatura agrônômica. Esta fase incorporou técnicas de análise estatística multivariada conforme preconizado por Hair *et al.* (2018) para sistemas de apoio à decisão com validação operacional implementando o *framework* de resiliência de sistemas distribuídos descrito por Avizienis *et al.* (2004), avaliando especialmente os mecanismos de *fallback* e recuperação automática. A metodologia seguiu os princípios de teste de sistemas críticos definidos na norma IEC 61508 para software de missão crítica, e uma validação de desempenho foi aplicada ao modelo de avaliação de desempenho de sistemas especialistas proposto por Russell e Norvig (2020), com ênfase nas métricas de qualidade de serviço (QoS) para sistemas em tempo real. A análise considerou especialmente os critérios de latência e *throughput* estabelecidos por Jain (1991) para sistemas distribuídos.

O processo de validação incorporou ainda técnicas de aprendizado de máquina explicável (XAI) conforme proposto por Arrieta *et al.* (2020), garantindo a rastreabilidade das recomendações geradas pelo sistema. Esta abordagem permitiu validar não apenas a precisão dos resultados, mas também a coerência agrônômica das inferências realizadas pelo modelo generativo.

Para o funcionamento do sistema as informações podem ser fornecidas de duas formas, na primeira forma, o usuário da aplicação abastecerá as informações com a região que permitirá a realização do cultivo, a cidade a qual se encontra a área de plantio, o tipo de solo que a cultura será plantada e a mensuração da área disponível em hectares.

Figura 4 - Tela inicial para abastecimento de informações do solo para plantio.



Após o abastecimento pelo usuário, o método de similaridade é efetuado e os bancos de dados que se encontram nas bibliotecas instaladas oriundas do site Embrapa Solos com acesso gratuito, são confrontados. O confronto de informações abastece o sistema criado a partir da receita pré-definida e assim os resultados são gerados.

As considerações pertinentes para a análise do sistema são limitadas para projeção de 6 (seis) anos de produção por estar relacionado a idade em que planta café gera o maior volume de produção do grão. Os custos investidos estão implementados com margem de perda de 20%, média referente aos dados técnicos obtidos (Comissão de fertilidade do solo do estado de Minas Gerais, 1999). O sistema também gera a previsão dos custos investidos em fertilizantes em 6 anos, custo de mão de obra de plantio, custos de mão de obra de manutenção, custo de mão de obra de colheita, custo de mão de obra para beneficiamento, lucros estimados e receita estimada.

RESULTADOS

Para a análise dos resultados gerados pelo sistema, foram utilizadas as informações de produção do café publicadas pelo IBGE em 2023, bibliografia orientada através de técnicos do órgão Emater Volta Redonda e orientação técnica detalhada do custo de implantação gerado pela Empresa de Assistência Técnica e Extensão Rural.

Figura 5 - Custo de implantação caracterizado para o plantio do café de forma convencional.

 CUSTO DE IMPLANTAÇÃO AGRICULTURA FAMILIAR - CAFÉ - PLANTIO CONVENCIONAL - ALTA TECNOLOGIA - Topografia mecanizada 2025 - VOLTA REDONDA - RJ				
Produtividade Média 3.600 kg/ha (60 sc)		Espaçamento utilizado: 3,5x0,5		nº de mudas /ha: 5.714
DISCRIMINAÇÃO	Quantidade	unidade	R\$ / unidade	VALOR TOTAL (R\$)
I - DESPESAS DE IMPLANTAÇÃO				
1 - Operação com máquinas:				
1.1 - Aração Trator 75 cv	8,00	hora trator	200,00	1.600,00
1.2 - Gradagem Trator 75 cv	4,00	hora trator	200,00	800,00
1.3 - Sulcação Trator 75 cv	1,00	hora trator	200,00	200,00
1.4 - Distribuição do calcário Trator 75 cv	2,00	hora trator	200,00	400,00
1.5 - Distribuição do adubo plantio Trator 75 cv	1,00	hora trator	200,00	200,00
1.6 - Distribuição do adubo cobertura Trator 75 cv	3,00	hora trator	200,00	600,00
1.7 - Aplicação de herbicida na entrelinha Trator 75	3,00	hora trator	200,00	600,00
1.8 - Aplicação de defensivos e adubo foliar Tr. 75	3,00	hora trator	200,00	600,00
SUBTOTAL				5.000,00
2 - Insumos				
2.1 - Calcário	3,00	tonelada	600,00	1.800,00
2.2 - Adubo superfosfato simples	0,86	tonelada	2.800,00	2.396,60
2.3 - Adubo termofosfato	0,29	tonelada	2.500,00	712,50
2.4 - Adubo cloreto de potássio	0,17	tonelada	3.600,00	615,60
2.5 - Adubo uréia	0,06	tonelada	4.200,00	239,40
2.6 - Adubo foliar	1,00	litro	43,00	43,00
2.7 - Herbicida para entrelinha - Glyphosato	9,00	litro	26,00	234,00
2.8 - Herbicida para entrelinha - Heat	1,00	frasco de 350 g	609,00	609,00
2.9 - Herbicida para linha - Yamato	1,00	litro	670,00	670,00
2.10 - Inseticida e Fungicida - Verdadero	1,00	kg	362,00	362,00
2.11 - Mudas (com replantio)	6.300,00	unidade	1,50	9.450,00
SUBTOTAL				12.223,00
3 - Mão de Obra serviços diversos				
Ajudante trator, adubação, herbicida, análise de solo, replantio, capina, irrigação e demais atividades.	12,00	SM com encargos	3.000,00	36.000,00
4 - Irrigação	1,00	ha	23.000,00	23.000,00
5 - Outros:				
5.1 - Análise de Solo	2,00	unidade	25,00	50,00
5.2 - Assistência Técnica	12,00	visitas	300,00	3.600,00
SUBTOTAL				3.650,00
TOTAL DAS DESPESAS POR HECTARE				79.873,00


Carlos Patricio de Souza Rangel
 Engenheiro Agrônomo
 CREA/RJ: 1995102035
 Emater - Rio ID: 26961270
 Escritório de Volta Redonda

Fonte: Emater-Rio (2025).

Os dados gerados pelo sistema foram confrontados com as informações publicadas pelas fontes, conforme **figura 5**, mostrando uma precisão de 82% para os insumos no plantio de café no formato convencional e 100% de precisão para os custos de implementação, caracterizado por produzir em média 60 sacas por hectare.

Detalhamento dos resultados gerados pelo sistema

Após a inserção de dados, o sistema aplica o método de similaridade com as informações de região do plantio, cidade ao qual será realizado o plantio, tipo de solo, seleção de cultura e área a ser plantada. Após o preenchimento, o próximo passo é clicar para calcular os resultados e automaticamente é apresentado as informações.

Figura 6 - Resultado da recomendação agrícola detalhada com resultado recomendado de acordo com as informações fornecidas.



```
===== RECOMENDAÇÃO AGRÍCOLA DETALHADA =====  
  
Data: 19/05/2025 13:41  
  
>> DADOS DA PROPRIEDADE <<  
  
Região: Sul Fluminense  
Cidade: Volta Redonda  
Tipo de Solo: Espodosolos  
Cultura: Café  
Área: 1.0 hectare
```

Fonte: Os autores.

Conforme a recomendação gerada pelo sistema, como mostra a **figura 6**, os dados gerados serão característicos conforme a região escolhida pelo usuário (Sul Fluminense), cidade (Volta Redonda), tipo de solo comum na região (Espodosolo), cultura escolhida para iniciar o plantio (Café) e área disponível (1 hectare).

Figura 7 - Resultado das recomendações técnicas de acordo com as informações fornecidas.

>> RECOMENDAÇÕES TÉCNICAS <<	
- Época de Plantio:	mar, abr, mai, jun, jul, ago
- Muda Necessárias:	6300.0 Unid. (6300.00 unid./ha)
- Adubação (kg):	
* Nitrogênio (N):	120.00 (120.00 kg/ha)
* Fósforo (P):	100.00 (100.00 kg/ha)
* Potássio (K):	100.00 (100.00 kg/ha)
- Água Necessária:	6000.00 m ³ /mês (6000.00 m ³ /mês/ha)
- Equipamentos:	Trator médio, sistema de irrigação

Para orientação do produtor rural, o sistema informa a melhor época para realizar o plantio, dados importantes para o planejamento do início da plantação. A orientação se estende com a quantidade necessária de mudas a serem plantadas de acordo com a área definida na etapa de abastecimento de dados pelo usuário, juntamente com a estimativa de quantidade de adubação, demanda de água e equipamentos necessários para suprir as necessidades da plantação em todo o período de 6 anos.

Figura 8 - Resultado das estimativas de produção de acordo com as informações fornecidas.

>> ESTIMATIVAS DE PRODUÇÃO <<	
- Produção Estimada Total:	3,600.00 kg
- Produção Estimada por Hectare:	60.00 kg/ha
- Sacas Produzidas Total:	60.00 sacas (60kg cada)
- Sacas Produzidas por Hectare:	60.00 sacas/ha
- Preço médio por saca:	R\$ 2,300.00

Os dados de estimativa de produção são referentes a quantidade produzida ao final do período de 6 anos, este período é o ápice da produção na cultura do café. As informações geradas são detalhadas em estimativa total (para uma área de 1 hectare, de acordo com os dados abastecidos na simulação

inicial), estimativa por hectare permitindo uma visão fracionada da produção total, mensuração no total de sacas produzidas (para cada saca são 60 kg de grãos), sacas produzidas por hectare possibilitando a verificação do tipo de plantio entre característica tradicional ou adensado. O preço médio por saca é explícito conforme valores atualizados de acordo com o dia ao qual é realizada a simulação.

Figura 9 - Resultado da projeção financeira detalhada de acordo com as informações fornecidas.

>> PROJEÇÃO FINANCEIRA DETALHADA <<	
=== CUSTOS ===	
- Custo com Mudas:	R\$ 13,230.00 (R\$ 13,230.00/ha)
- Custo com Fertilizantes:	R\$ 2,000.00 (R\$ 2,000.00/ha)
- Custo com Mão-de-Obra:	R\$ 36,000.00 (R\$ 36,000.00/ha)
- Outros Custos:	R\$ 5,650.00 (R\$ 5,650.00/ha)
- Custo Total:	R\$ 79,880.00 (R\$ 79,880.00/ha)

A descrição da projeção financeira detalhada permite a visão de investimento a ser realizada para os custos variáveis entre o início do plantio da cultura até a colheita após 6 anos de idade da planta café. No detalhamento financeiro é possível contabilizar o custo com mudas a serem plantadas na área disponível (1 hectare), custo por hectare, valores para o uso de fertilizantes, outros custos aos quais são englobados a manutenção da lavoura (limpeza, monitoramento de plantas invasoras, monitoramento de pragas) e o custo total do investimento contabilizando as variáveis anteriormente detalhadas.

Figura 10 - Resultado da receita de acordo com as informações fornecidas.

=== RECEITAS ===	
- Receita Total:	R\$ 138,000.00 (R\$ 138,000.00/ha)

A informação da receita mostra ao produtor a previsão de retorno sobre os gastos realizados durante os 6 anos da plantação do café. A contabilização da receita total permite analisar a viabilidade da implementação do projeto

incluindo a construção e conservação da lavoura até o tempo máximo de produção da cultura.

Figura 11 - Resultado de acordo com as informações fornecidas.

=== RESULTADOS ===
- Lucro Total: R\$ 58,120.00 (R\$ 58,120.00/ha)
- Margem de Lucro: 42.12%
- ROI (Retorno sobre Investimento): 72.76%
- Ponto de Equilíbrio: 34.73 sacas (34.73 sacas/ha)
- Custo por Saca Produzida: R\$ 1,331.33

Conforme resultados da **figura 11**, a simulação para a área de 1 hectare de cultivo de café na região sudeste, localizada na cidade de Volta Redonda, estima o lucro total para a produção de café na duração de 6 anos. Além do lucro total, a margem de lucro em porcentagem é apresentada, possibilitando a comparação entre um cenário previsto e um cenário real. O retorno sobre investimento (R.O.I), exibe em porcentagem a estimativa do resultado que o produtor recebe após a finalização da colheita. A previsão do ponto de equilíbrio se faz necessário para apresentar ao investidor a mínima produção necessária para se pagar o investimento realizado, com valores em quantidades de sacas e sacas por hectares. Por fim, em valores atualizados de acordo com o dia em que a simulação está sendo realizada, o custo por saca produzida também é apresentado, possibilitando que o sistema de previsibilidade auxilie a tomada de decisão na negociação do valor de venda de produção.

Figura 12 - Análise de sensibilidade de acordo com as informações fornecidas.

>> ANÁLISE DE SENSIBILIDADE <<	
- Cenário Pessimista (-20% produção):	
Lucro: R\$ 30,520.00 (R\$ 30,520.00/ha)	
- Cenário Realista:	
Lucro: R\$ 58,120.00 (R\$ 58,120.00/ha)	
- Cenário Otimista (+20% produção):	
Lucro: R\$ 85,720.00 (R\$ 85,720.00/ha)	

A exibição da análise de sensibilidade permite que as partes interessadas do projeto possam se preparar diante variáveis ao decorrer do plantio até a colheita. O cenário pessimista aponta uma previsão deficitária em 20%, esse valor é referente à porcentagem média para as perdas de produção durante intercorrências ao longo da temporada de plantio e colheita (Comissão de fertilidade do solo do estado de Minas Gerais, 1999).

Figura 13 - Análise de sustentabilidade de acordo com as informações fornecidas.

>> SUSTENTABILIDADE <<	
- Pegada de Carbono Total: 1.20 ton CO ₂ eq	
- Pegada de Carbono por Hectare: 1.20 ton CO ₂ eq/ha	
- Pegada de Carbono por Saca: 0.02 ton CO ₂ eq/saca	

O sistema mostra características que entram na análise para uma produção sustentável. Os indicadores de pegada de carbono são usados para demonstrar, a partir da sua máxima produção, a quantificação de elementos nocivos para a atmosfera, gerados a partir da emissão de dióxido de carbono. Em média, um indivíduo adulto pode gerar o mínimo de 2 toneladas de dióxido de carbono para a atmosfera, sendo assim, é válido analisar que para um plantio de café, segundo ARAÚJO HAMASAKI, P. S. (Balanço de carbono em uma lavoura de

café orgânico. Lavras - MG, 2023) é possível emitir 50 kg de dióxido de carbono em 60 kg de grãos produzidos, permanecendo dentro dos parâmetros normais de emissão.

DISCUSSÃO

A agricultura moderna enfrenta desafios complexos, como a necessidade de aumentar a produtividade, reduzir custos e minimizar impactos ambientais. Nesse contexto, a previsibilidade de produção surge como uma ferramenta essencial para auxiliar os agricultores na tomada de decisões estratégicas. Este capítulo discute os resultados obtidos por um sistema desenvolvido para prever a viabilidade de investimento em culturas agrícolas auxiliando o produtor iniciante a tomada de decisão na realização do projeto de cultivo, com foco no café. Utilizando algoritmos em Python e dados públicos da Embrapa e Emater, a abordagem integra tecnologia, sustentabilidade e análise financeira, oferecendo *insights* valiosos para o setor agrícola.

É pertinente salientar que o sistema desenvolvido não descarta a orientação por técnicos e não dispensa a emissão de relatórios para procedimentos orientativos para o processo de plantio do café. O sistema desenvolvido demonstra como a combinação de *Big Data*, Inteligência Artificial (IA) e Internet das Coisas (IoT) pode transformar a gestão agrícola. Ao utilizar algoritmos de similaridade e uma chave de API para interagir com o Chat GPT, o sistema consegue gerar recomendações técnicas precisas com base em dados históricos e em tempo real. Essa integração tecnológica não apenas otimiza o uso de recursos como água, fertilizantes e mão de obra, mas também reduz desperdícios e custos operacionais, tornando as fazendas mais eficientes e sustentáveis.

Os resultados apresentados pelo sistema foram validados confrontando-os com dados publicados pelo IBGE e recomendações técnicas da Emater, alcançando uma precisão de 100% para os custos relacionados ao cultivo tradicional de café. Essa assertividade é crucial para que os agricultores possam confiar nas projeções e tomar decisões embasadas nos dados recomendados. Por exemplo, o sistema fornece estimativas detalhadas de produção, custos e receitas, além de uma análise de sensibilidade que considera cenários pessimistas, realistas

e otimistas. Essa abordagem multidimensional permite uma visão abrangente dos riscos e oportunidades associados ao investimento.

Além da viabilidade financeira, o sistema incorpora uma análise de sustentabilidade, calculando a pegada de carbono equivalente da produção. No caso estudado, a pegada de carbono foi de 1,20 tonelada de CO₂ por hectare, um dado relevante para agricultores que buscam alinhar suas práticas às demandas globais por produção sustentável. A inclusão desse indicador reforça a importância de integrar critérios ambientais às análises econômicas, promovendo uma agricultura mais responsável.

A metodologia adotada pelo sistema é replicável para outras culturas e regiões, desde que haja dados disponíveis para alimentar a aplicação. A flexibilidade do modelo permite adaptações conforme as particularidades de cada cultura, tipo de solo e condições climáticas. Além disso, a utilização de bancos de dados públicos, como os da Embrapa, garante acesso livre e democrático à informação, facilitando a adoção da tecnologia por pequenos e médios produtores.

CONCLUSÃO

A previsibilidade de produção, aliada a tecnologias como IA e *Big Data*, representa um avanço significativo para a agricultura. O sistema discutido neste capítulo não apenas certifica a viabilidade técnica e financeira do cultivo de café, mas também abre caminho para aplicações em outras culturas. É válido destacar que o projeto não substitui a análise técnica elaborada por profissionais agrônomos, sendo necessário a solicitação de revisão nos relatórios gerados pelo sistema e complementação das informações geradas com instruções mais detalhadas para variáveis endêmicas.

Futuras pesquisas podem explorar a integração de mais variáveis, como mudanças climáticas e flutuações de mercado, para aprimorar ainda mais a precisão das previsões. A adoção em larga escala dessas ferramentas tem o potencial de revolucionar o setor agrícola, tornando-o mais eficiente, sustentável e resiliente.

REFERÊNCIAS

ARRIETA, A. B. *et al.* Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, v. 58, p. 82-115, 2020.

AVIZIENIS, A. *et al.* Basic concepts and taxonomy of dependable and secure computing. *IEEE Transactions on Dependable and Secure Computing*, v. 1, n. 1, p. 11-33, 2004.

COMISSÃO DE FERTILIDADE DO SOLO DO ESTADO DE MINAS GERAIS – CFSEMG. Recomendações para o uso de corretivos e fertilizantes em Minas Gerais: 5ª Aproximação. Viçosa: CFSEMG, 1999.

EMATER-RJ. Manual Técnico de Culturas. Rio de Janeiro, 2022.

HAMASAKI, Paulo Seiiti Araújo. Balanço de carbono em uma lavoura de café orgânica. 2023. Monografia (Bacharelado em Engenharia Florestal) — Universidade Federal de Lavras, Lavras, 2023.

MACHINE LEARNING NA SIDERURGIA: REVISÃO SISTEMÁTICA DA APLICAÇÃO DE IA NA MANUTENÇÃO PREDITIVA EM LAMINADORES DE TIRAS À QUENTE AÇOS PLANOS

Antonio Carlos Pimentel Junior
Instituto Federal do Rio de Janeiro (IFRJ)

Leonardo de Carvalho Vidal
Instituto Federal do Rio de Janeiro (IFRJ)

RESUMO

Objetivo: A inteligência artificial aplicada à manutenção preditiva é uma das principais ferramentas da Indústria 4.0, promovendo avanços que elevam a disponibilidade e confiabilidade dos ativos. Tecnologias como *Machine Learning* e *Digital Twins* são empregadas para desenvolver modelos preditivos que antecipam falhas e otimizam estratégias de manutenção. Na siderurgia, onde os equipamentos operam sob condições extremas, os desafios são ainda maiores, especialmente em áreas críticas como os laminadores. Esta revisão sistemática examina a literatura sobre o uso dessas tecnologias na manutenção preditiva, destacando metodologias aplicadas, desafios de implementação e benefícios em confiabilidade e disponibilidade. **Métodos:** A seleção dos artigos utilizou a metodologia PRISMA, com critérios de inclusão e exclusão. **Resultados:** A literatura indica limitações práticas como a complexidade do processo, integração com sistemas legados e baixa confiabilidade das bases de dados de manutenção. Há também a falta de estudos de longo prazo que validem os impactos dessas soluções. Em contrapartida, os estudos apontam ganhos significativos na redução de falhas e no suporte à tomada de decisão, especialmente quando há integração com dados consistentes e atualizados. **Conclusão:** Esta revisão sistemática reforça o papel estratégico da inteligência artificial na gestão de ativos, indicando caminhos promissores para a adoção prática dessas tecnologias no setor siderúrgico.

Palavras-chave: Inteligência artificial; aprendizado de máquina; manutenção preditiva; indústria siderúrgica; laminador.

INTRODUÇÃO

A Indústria 4.0 representa uma transformação significativa no setor industrial, impulsionada pela incorporação de tecnologias avançadas como inteligência artificial, *Machine Learning*, *Digital Twins*, *Similarity Algorithms*, *IoT* e *big data*. Essas inovações viabilizam a automação e a análise inteligente de ativos e processos produtivos, com pouca necessidade de intervenção humana (AZEEM *et al.*, 2022).


A manutenção preditiva tem como objetivo antecipar falhas em equipamentos antes que elas aconteçam, reduzindo paradas inesperadas e permitindo um planejamento mais eficiente das intervenções da manutenção. Dentro desse contexto, *Machine Learning* exerce um papel extremamente importante, ao permitir que os sistemas industriais aprendam com dados históricos, respondam de forma adaptativa a mudanças no ambiente e tomem decisões baseadas em informações em tempo real (LEONARDI *et al.*, 2020).

Neste contexto os gêmeos digitais (*Digital Twins*) representam uma revolução na forma de interagir com ativos industriais. Trata-se de réplicas digitais de equipamentos físicos que simulam em tempo real o comportamento de suas variáveis operacionais, gerando uma referência da saúde do ativo. Essas réplicas são alimentadas por dados obtidos de sensores e sistemas de automação, permitindo uma visão detalhada do equipamento sob diferentes cenários de operação (TAO *et al.*, 2019).

No setor industrial, estima-se que os custos totais de manutenção variem entre 15% e 70% do valor do produto final. Esses custos incluem reparos e substituições de ativos, paradas não programadas por emergências, atrasos e mão de obra. Além das perdas financeiras, falhas na manutenção podem ocasionar riscos ambientais e a segurança de pessoas (THOMAS, 2018).


Para enfrentar os crescentes desafios ambientais e operacionais, a indústria siderúrgica tem recorrido às tecnologias da Indústria 4.0, como inteligência artificial, *Machine Learning* e *IoT* integrados a modelos preditivos. Essas soluções digitais permitem não apenas o monitoramento em tempo real dos processos produtivos, mas também a antecipação de falhas e otimização do processo com o auxílio da manutenção preditiva (BAG *et al.*, 2020).

Entendendo um pouco sobre o processo siderúrgico, ele tem início com a preparação das matérias-primas (minério de ferro, carvão, calcário e dolomita), que são processadas em unidades como pátios de minério e coquearias. O alto-forno funde o minério de ferro utilizando o coque como redutor, gerando o ferro-gusa. Esse ferro é transferido para a aciaria, onde é refinado e transformado em aço líquido. O aço é solidificado no lingotamento contínuo e segue para os laminadores, onde é conformado em produtos como chapas, tiras e bobinas. (HORIZONTE AMBIENTAL, 2023). A Figura 1 apresenta o fluxo de processos da siderurgia.



Por definição, um laminador de tiras a quente é um conjunto de equipamentos industriais utilizados no processo de conformação mecânica do aço, no qual placas são aquecidas em fornos a temperaturas elevadas (geralmente entre 1.100 e 1.250 °C) e, em seguida, passam por sucessivos conjuntos de rolos que reduzem sua espessura e aumentam seu comprimento, formando tiras contínuas de aço. Esse processo visa melhorar as propriedades mecânicas do material, além de atender às dimensões exigidas para aplicação em setores como automotivo, construção civil, naval e fabricação de tubos. (SILVA & CUNHA, 2016). A Figura 2 apresenta a composição de uma linha de laminação à quente aços planos.

Figura 2 - Laminador de Tiras à Quente, aços planos.



Fonte: SONG L. (2022).

A aplicação dessa abordagem tecnológica na siderurgia, quando se trata de laminadores de tiras a quente, encontra desafios específicos do processo. Eles operam em condições severas de temperatura, pressão e velocidade, o que exige sensores robustos, modelos de predição confiáveis e infraestrutura digital resiliente (SILVA *et al.*, 2021).

A complexidade do processo de laminação demanda também a integração de dados vindos de diferentes fontes, exigindo interoperabilidade destes sistemas (FERREIRA & AMORIM, 2020).

A literatura também aponta que a implantação de soluções baseadas em IA e *Machine Learning* em plantas industriais tradicionais, cruzam em fatores como a obsolescência dos sistemas legados, a falta de profissionais qualificados e a resistência cultural à adoção destas tecnologias (KUMAR *et al.*, 2020).

Além disso, o retorno sobre o investimento (ROI) de projetos de transformação digital ainda é um tema complexo, exigindo estudos de caso e metodologias específicas para cada processo (XIE *et al.*, 2021).

Apesar desses obstáculos, empresas siderúrgicas vêm avançando na digitalização dos processos de manutenção, pela necessidade de reduzir custos, aumentar a produtividade e garantir a segurança operacional. O monitoramento preditivo baseado em ML tem sido aplicado com sucesso em motores de corrente contínua, cilindros de laminação e sistemas hidráulicos com ajuste automático, trazendo ganhos relevantes de performance operacional (SANTOS *et al.*, 2022 & MARQUES *et al.*, 2023).

Portanto, a fim de estimular os investimentos e pesquisas na área da siderurgia, mas precisamente em laminadores de tiras à quente, buscou-se

realizar uma análise dos principais desafios e oportunidades na implantação de modelos preditivos utilizando *Machine Learning* na manutenção.

MÉTODOS

Metodologia PRISMA - Análise da literatura sobre o uso de *Machine Learning* na manutenção preditiva em Laminadores de Tiras à quente Aços Planos

A elaboração desta revisão sistemática seguiu a metodologia PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*). O objetivo foi reunir e avaliar os estudos disponíveis na literatura científica sobre a aplicação da Inteligência artificial, *Machine Learning* e *Digital Twins* em estratégias de manutenção preditiva. Com o foco na aplicação em laminadores de tiras à quente aços planos, na indústria siderúrgica.

Estratégia de busca (Search)

A busca bibliográfica utilizou como base de dados as ferramentas de pesquisa: Google Acadêmico, *ResearchGate* e *SciELO*. Para aumentar a assertividade da busca, foram aplicados operadores booleanos (AND/OR) nas seguintes combinações: "*Machine Learning*" AND "*Predictive Maintenance*" AND "*Steel Industry*", "*Rolling Mill*" AND "*Machine Learning*" AND "*Predictive Maintenance*", "*Artificial Intelligence*" AND "*Rolling Mill*" AND "*Machine Learning*", "*Artificial Intelligence*" AND "*Steel Industry*" AND "*Machine Learning*".

CrITÉrios de inclusão e exclusão (Appraisal)

Foram definidos os seguintes critérios de inclusão: Estudos que aplicam inteligência artificial, algoritmos de *Machine Learning*, *Digital Twins* ou manutenção preditiva na siderurgia, mais precisamente em laminadores de tiras à quente.

Foram definidos os seguintes critérios de exclusão: Trabalhos que não apresentam resultados práticos ou não discutem a aplicação direta no setor industrial siderúrgico e artigos duplicados.

Síntese e Organização (*Synthesis*)

Os artigos selecionados foram organizados em uma planilha contendo as seguintes variáveis: Autor e ano, objetivo do estudo, tipo de equipamento analisado, algoritmo de IA utilizado, tipo de dado analisado, resultados alcançados, desafios e limitações identificadas.


Análise dos Dados (*Analysis*)

A análise foi realizada de forma qualitativa, com foco na comparação entre os métodos aplicados, ganhos e desafios encontrados em cenários siderúrgicos, mais precisamente em laminadores de tiras à quente aços planos. Foram observadas também as contribuições práticas dos estudos, estrutura de automação, integração com sensores industriais, tratamentos de dados e evidências de redução de custos ou aumento de disponibilidade dos ativos. Teve o objetivo de identificar padrões recorrentes de desafios enfrentados, como interoperabilidade com sistemas legados, falta ou má qualidade de dados históricos de manutenção, e demais limitações para implantação desta tecnologia.

Fluxograma PRISMA

Conforme os dados da figura 3, a identificação inicial resultou em 66 estudos encontrados nas ferramentas de pesquisa. Durante a etapa de triagem, foram removidos estudos duplicados e trabalhos com abordagens repetidas e linhas de pesquisa similares, resultando em 57 estudos únicos. Na fase de elegibilidade 55 estudos foram considerados relevantes ao tema, com base na leitura dos títulos, resumos e palavras-chave. Por fim, após a leitura completa e aplicação dos critérios de inclusão e exclusão, 52 estudos foram selecionados para compor a análise final da revisão sistemática.

Figura 3 - Fluxograma metodologia PRISMA.



RESULTADOS

Como resultado, foi identificado que o maior número de publicações referentes ao laminador de tiras à quente aços planos, foi relacionado ao laminador de acabamento (*Finishing Mill*), que é um setor dentro do processo de laminação responsável por reduzir a espessura da tira, local onde possui maior número de interações entre variáveis de controle de processo. No laminador de acabamento, alguns estudos foram relacionados a uma única cadeira de laminação (projeto piloto), gerando modelos preditivos a serem replicados posteriormente (KROT *et al.*, 2020; DONG *et al.*, 2022; GUO *et al.*, 2023; JAKUBOWSKI *et al.*, 2021b; JIANG & YIN, 2017; JING *et al.*, 2023b).

Outras pesquisas foram voltadas para previsibilidade de desgaste de cilindros de trabalho (*Work Rolls*) (ANAGIANNIS *et al.*, 2020; JAKUBOWSKI *et al.*, 2021a; JIAO *et al.*, 2021; KOVACIC *et al.*, 2019; LEBRUN *et al.*, 2013) e em

cilindros de encosto (*Backup rolls*) (YUAN *et al.*, 2023), que representa custos elevados para fabricação.

Outra frente de estudo foi em relação ao laminador desbastador (*Roughing Mill*), que é uma cadeira de laminação intermediária responsável por reduzir largura e espessura do esboço, antes de sua entrada no laminador de acabamento, foi estudado por MA *et al.* (2021a).

Entre outros subsistemas do processo de laminação a quente, foram identificados estudos que abordam o monitoramento de mesas de rolos (JUNICHI & YUKINORI, 2020), resfriamento laminar para controle de temperatura (WANG & PENG, 2023) e sistemas de controle com realimentações, utilizando dados do processo (LI & DING, 2020).

Quanto aos estudos direcionados para ativos inseridos dentro dos laminadores, também foram realizados trabalhos com caixas de engrenagens (*gearboxes*), motores (FAGARASAN *et al.*, 2004; MA *et al.*, 2023; SARDA *et al.*, 2021), equipamento *Looper* para controle de fluxo de massa entre as cadeiras do trem acabador (GARCIA-BELTRAN *et al.*, 2004; JIANG *et al.*, 2021; MARCU *et al.*, 2004, 2008), mancais (*bearings*) (FARINA *et al.*, 2015; PAN *et al.*, 2016a; PENG *et al.*, 2022) e bombas (*pumps*) (GOODE *et al.*, 2000), todos modelos de machine learning voltados para manutenção preditiva. Na tabela 1, veremos um comparativo das vantagens e desafios encontrados nos estudos durante a aplicação de modelos de machine learning no laminador de tiras à quente.

Comparativo dos estudos realizados em relação a implantação de *Machine Learning*

Tabela 1 - Comparativo realizado pelo autor após análise dos estudos.

Estudos	Vantagens	Desafios
Laminador de Acabamento (<i>Finishing Mill</i>) KROT <i>et al.</i> (2020) DONG <i>et al.</i> (2022) GUO <i>et al.</i> (2023) JAKUBOWSKI <i>et al.</i> (2021b) JIANG & YIN <i>et al.</i> (2027) JING <i>et al.</i> (2023b)	1)Previsibilidade de falhas; 2)Manutenção assertiva e otimizada; 3) Redução dos custos de manutenção;	1)Alta complexidade das variáveis de controle; 2)Sistemas legados, obsoletos; 3)Baixa confiabilidade de dados de manutenção; 4)Investimento elevado;

Estudos	Vantagens	Desafios
Laminador Desbastador (<i>Roughing mill</i>) MA <i>et al.</i> (2021a)	1)Previsibilidade de falhas; 2)Manutenção assertiva e otimizada; 3) Redução dos custos de manutenção;	1)Ambiente agressivo; 2)Sistemas legados, obsoletos; 3)Baixa confiabilidade de dados de manutenção;
Cilindros de trabalho (<i>Work rolls</i>) ANAGIANNIS <i>et al.</i> (2020) JAKUBOWSKI <i>et al.</i> (2021a) JIAO <i>et al.</i> (2021) KOVACIC <i>et al.</i> (2019) LEBRUN <i>et al.</i> (2013)	1)Alta precisão preditiva; 2)Manutenção assertiva e otimizada; 3)Redução dos custos de manutenção; 5)Redução de custo e aumento de vida útil dos cilindros;	1)Ambiente agressivo; 2)Alta complexidade dos sensores; 3)Investimento elevado;
Cilindros de encosto (<i>Backup rolls</i>) YUAN <i>et al.</i> (2023)	1)Alta precisão preditiva; 2)Manutenção assertiva e otimizada; 3) Redução dos custos de manutenção; 4)Redução de custo e aumento de vida útil dos cilindros;	1)Ambiente agressivo; 2)Alta complexidade dos sensores; 3)Investimento elevado;
Mesas de rolos (<i>Table rolls</i>) JUNICHI & YUKINORI (2020)	1)Alta precisão preditiva; 2)Manutenção assertiva e otimizada; 3) Redução dos custos de manutenção;	1)Ambiente agressivo; 2)Alta rotatividade de ativos para manutenção; 3) Dados ruidosos;
Sistema de resfriamento laminar (<i>Laminar Flow</i>) WANG & PENG (2023)	1) Controle térmico eficiente, evitando desvios de qualidade;	1)Interação em tempo real com sistemas legados, obsoletos;
Controle por feedback (<i>Feedback control</i>) LI & DING (2020)	1) Respostas rápidas a variações do processo;	1)Interação em tempo real com sistemas legados, obsoletos.
Caixas redutoras e motores (Gearboxes e motors) FAGARASAN <i>et al.</i> (2004) MA <i>et al.</i> (2023) SARDA <i>et al.</i> (2021)	1)Alta precisão preditiva; 2)Baixa complexidade; 3)Possibilidade de replicação para outros ativos da linha;	1)Ambiente agressivo; 2)Alta rotatividade de ativos para manutenção; 3) Dados ruidosos;
Looper (controle de fluxo massa entre as cadeiras de laminação) GARCIA-BELTRAN <i>et al.</i> (2004) JIANG <i>et al.</i> (2021) MARCU <i>et al.</i> (2004, 2008)	1)Alta precisão preditiva; 2)Alto sensoriamento; 3)Possibilidade de replicação para outras cadeiras de laminação;	1)Ambiente agressivo; 2)Alta rotatividade de ativos para manutenção; 3) Dados ruidosos;

Estudos	Vantagens	Desafios
Mancais (Bearings) FARINA <i>et al.</i> (2015) PAN <i>et al.</i> (2016a) PENG <i>et al.</i> (2022)	1)Alta precisão preditiva; 2)Baixa complexidade; 3)Possibilidade de replicação para outros ativos da linha;	1)Ambiente agressivo; 2)Alta rotatividade de ativos para manutenção; 3) Dados ruidosos;
Bombas (Pumps) GOODE <i>et al.</i> (2000)	1)Alta precisão preditiva; 2)Baixa complexidade; 3)Possibilidade de replicação para outros ativos da linha;	1)Ambiente agressivo; 2)Alta rotatividade de ativos para manutenção; 3) Dados ruidosos;

Análise geral das principais vantagens encontradas nos estudos

As principais vantagens identificadas nos artigos incluem a redução de custos operacionais, a otimização do ciclo de vida dos ativos devido a capacidade de prever falhas antecipadamente, o que resulta em uma manutenção preditiva mais eficiente.

Jakubowski *et al.* (2024) realizaram uma análise abrangente de estudos sobre o uso de inteligência artificial na manutenção preditiva da indústria siderúrgica, destacando que a aplicação de técnicas de *machine learning* contribui significativamente para a redução de falhas inesperadas, extensão da vida útil dos equipamentos e diminuição de custos operacionais. Os autores também observaram um aumento no interesse por estes métodos, e enfatizaram a importância de integrar essas tecnologias aos planos de manutenção já existentes nas indústrias.

De forma complementar, Ayyamperumal *et al.* (2024) propôs uma estrutura de manutenção preditiva baseada em IA com uso de gêmeos digitais, relatando melhoria de 35% nos diagnósticos preditivos, uma redução de 40% em paradas não planejadas e otimização de 25% nos custos de manutenção. A integração com modelos preditivos foi apontada como essencial para tomadas de decisão em tempo real e para o aumento da eficiência operacional.

Análise geral dos principais desafios encontrados nos estudos

Qualidade e Integridade dos Dados: Com base no estudo Jakubowski *et al.* (2024), a performance dos algoritmos de aprendizado de máquina e dos modelos de gêmeos digitais está ligada à qualidade dos dados coletados. Em muitas plantas siderúrgicas a ausência de sensores inteligentes, e a falta de pontos de monitoramento em locais específicos, comprometem a confiabilidade das análises, dificultando a detecção de falhas ou padrões operacionais anormais. A presença de ruídos, dados incompletos ou desatualizados reduz a eficácia dos modelos preditivos.

Integração com Sistemas Legados: Com base no estudo Velmurugan *et al.* (2024) e Kumar & Das (2022), grande parte das instalações siderúrgicas ainda operam com sistemas legados, que utilizam protocolos de comunicação proprietários e arquiteturas fechadas. Essa limitação representa um obstáculo para a integração de soluções modernas baseadas em *IoT*, aprendizado de máquina e *big data*. A interoperabilidade entre sistemas antigos e novas plataformas digitais requer adaptações complexas, e muitas vezes, inviáveis financeiramente.

Custo Inicial de Implementação: Com base no estudo Tiensuu *et al.* (2020), Ayyamperumal *et al.* (2024), a modernização das plantas siderúrgicas para adoção de tecnologias baseadas em IA, demanda investimentos elevados, principalmente em infraestrutura computacional, atualização de dispositivos de automação, aquisição de sensores inteligentes e capacitação técnica das equipes. Além disso, o fato de muitos ativos da indústria serem obsoletos aumenta o custo de adequação, exigindo modificações significativas nos sistemas de controle existentes.

DISCUSSÃO

Oportunidades de estudos identificados na revisão

Falta de estudos a longo prazo: A maioria dos estudos disponíveis tem uma duração limitada, dificultando a avaliação do impacto a longo prazo das tecnologias na confiabilidade dos ativos. Pesquisas como as de Zhang *et al.*

(2020) e Zhang e Li (2021) destacam a importância de estudos a longo prazo para validar a eficácia das soluções de manutenção preditiva.

Escalabilidade das Soluções: Poucos estudos abordam como as soluções propostas se comportam em ambientes industriais de grande porte, o que limita a aplicação dessas tecnologias em indústrias de escala global. Artigos como Marquez *et al.* (2022) e Li *et al.* (2023), discutem a necessidade de adaptar os modelos para diferentes níveis de complexidade e infraestrutura.

Transparência dos Modelos de IA: Muitos modelos de *Machine Learning* ainda são considerados caixas pretas, o que gera desconfiança na aplicação dessas tecnologias em ambientes industriais críticos. Trabalhos como os de Jouini *et al.* (2020) e Huang *et al.* (2021) abordam a questão da transparência dos modelos de IA destacando a importância de desenvolver abordagens que possam fornecer explicações claras sobre as decisões dos modelos.

Integração de novas tecnologias com sistemas legados existentes: A integração de tecnologias avançadas com sistemas legados permanece um desafio muito grande. Wang *et al.* (2021), Singh & Gupta (2022), propõem soluções para melhorar a integração entre essas tecnologias, sugerindo uma abordagem menos agressiva que permita a adaptação com tecnologias obsoletas sem a necessidade de substituir toda a infraestrutura existente.

CONCLUSÃO DA REVISÃO

A partir desta revisão sistemática, foi possível compreender como a inteligência artificial vem se consolidando como uma ferramenta estratégica para a manutenção preditiva em ambientes industriais de alta complexidade, como os laminadores de tiras a quente na indústria siderúrgica. O levantamento dos estudos nos mostrou que técnicas de inteligência artificial como Machine Learning têm contribuído para antecipar falhas, otimizar rotinas de manutenção e ampliar a confiabilidade dos ativos.

Apesar dos avanços, ainda existem obstáculos importantes para implementação dessas tecnologias. A dificuldade de integração com sistemas de automação legados, a confiabilidade limitada das bases de dados de manutenção e a falta de estudos com acompanhamento de longo prazo são pontos que precisam ser aprofundados.

Por outro lado, quando esses modelos são bem implementados e alimentados por dados confiáveis, os ganhos operacionais podem ser bem elevados, inclusive em termos de retorno sobre o investimento. Isso reforça a importância de alinhar as estratégias de manutenção com a maturidade digital da empresa, e com o planejamento de médio a longo prazo da planta.

Como sugestão para pesquisas futuras, destaca-se a necessidade de desenvolver soluções híbridas que conectem a predição do *Machine Learning* à capacidade de simulação dos gêmeos digitais, de forma mais explicável e adaptável às particularidades de cada planta, pois a maioria dos laminadores ainda possuem sistemas de automação legados, com pouco sensoramento. Também seria interessante aprofundar os estudos sobre a interoperabilidade entre essas novas tecnologias e os sistemas já existentes nas fábricas, favorecendo uma transição mais viável e segura rumo à Indústria 4.0.

REFERÊNCIAS

ANAGIANNIS, I., NIKOLAKIS, N., ALEXOPOULOS, K., 2020. Energy-Based Prognosis of the Remaining Useful Life of the Coating Segments in Hot Rolling Mill. *Applied Sciences* 10, 6827. URL: <<https://www.mdpi.com/2076-3417/10/19/6827>>, doi:10.3390/app10196827. Acesso em: 10 de Janeiro de 2025.

AYYAMPERUMAL, A.; VENKATARAMANAN, V.; MANOHAR, R. Predictive maintenance of rolling mill using artificial intelligence and machine learning techniques. *Materials Today: Proceedings*, v. 97, p. 221-227, 2024. Disponível em: <<https://doi.org/10.1016/j.matpr.2024.02.264>>. Acesso em: 10 de Janeiro de 2025.

AZEEM, Mohd; HALEEM, Abid; JAVAID, Mohd. Symbiotic relationship between machine learning and Industry 4.0: A review. *Journal of Industrial Integration and Management*, v. 7, n. 3, p. 401–433, 2022. Disponível em: <<https://www.worldscientific.com/doi/10.1142/S2424862221300027>>. Acesso em: 20 de Setembro de 2024.

BAG, S. *et al.* Industry 4.0 and the circular economy: a literature review and future research directions. *Journal of cleaner production*, v. 277, p. 123652, 2020. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S095965262033656x>>. Acesso em: 20 de setembro de 2024.

DONG, J.; WANG, Y.; PENG, K. A Novel Fault Detection Method Based on the Extraction of Slow Features for Dynamic Nonstationary Processes. *IEEE Transactions on Instrumentation and Measurement*, v. 71, p. 1–11, 2022. Disponível em: <<https://ieeexplore.ieee.org/document/9656813/>>. Acesso em: 20 de Setembro de 2024.

FAGARASAN, I., TALEB, S., LESECQ, S., GENTIL, S., STUECHER, R., 2004. Signal-Based Diagnosis of Torsional Vibration of a Hot Rolling Mill Main Drive. IFAC Proceedings Volumes 37, 185–190. URL: <<https://linkinghub.elsevier.com/retrieve/pii/S1474667017310212>>, doi:10.1016/S1474-6670(17)31021-2. Acesso em: 20 de Setembro de 2024.

FARINA, M., OSTO, E., PERIZZATO, A., PIRODDI, L., SCATTOLINI, R., 2015. Fault detection and isolation of bearings in a drive reducer of a hot steel rolling mill. Control Engineering Practice 39, 35–44. URL: <https://linkinghub.elsevier.com/retrieve/pii/S0967066115000283>, doi:10.1016/j.conengprac.2015.02.001. Acesso em: 20 de Setembro de 2024.

FERREIRA, R.; AMORIM, R. Integração de Dados Industriais em Ambientes de Produção Siderúrgica: Um Estudo de Caso sobre Interoperabilidade. *Revista Produção e Desenvolvimento*, v. 6, n. 2, p. 12–21, 2020.

GARCIA-BELTRAN, A. *et al.* Looper and tension control in hot strip finishing mills based on nonlinear model predictive control. *Journal of Electrical and Automation Systems*, 2004. Disponível em: <<https://jeas.springeropen.com/articles/10.1186/s44147-022-00145-w>>. Acesso em: 20 de Setembro de 2024.

GOODE, J. *et al.* Roll wear prediction model for finishing stands of hot strip mill. *Wear*, v. 245, n. 1–2, p. 178–185, 2000. Disponível em: <https://www.researchgate.net/publication/233513416_Roll_wear_prediction_model_for_finishing_stands_of_hot_strip_mill>. Acesso em: 20 de Setembro de 2024.

GUO, H. *et al.* Quality-Related Process Monitoring and Diagnosis of Hot-Rolled Strip Based on Weighted Statistical Feature KPLS. *Sensors*, v. 23, p. 6038, 2023. Disponível em: <<https://www.mdpi.com/1424-8220/23/13/6038>>. Acesso em: 20 de Setembro de 2024.

HORIZONTE AMBIENTAL. Siderurgia: o que faz? Produção de ferro e aço fundido. Disponível em: <<https://horizonteambiental.com.br/siderurgia/>> 2023. Acesso em: 20 Setembro 2024.

HUANG, Y. *et al.* An overview of digital twin technology and its applications in manufacturing. *Journal of Manufacturing Systems*, [S.l.], v. 59, p. 414–426, 2021. Disponível em: <<https://doi.org/10.1016/j.jmsy.2021.05.009>>. Acesso em: 10 de Janeiro de 2025.

JAKUBOWSKI, J., STANISZ, P., BOBEK, S., NALEPA, G.J., 2021a. Anomaly Detection in Asset Degradation Process Using Variational Autoencoder and Explanations. *Sensors* 22, 291. URL: <https://www.mdpi.com/1424-8220/22/1/291>, doi:10.3390/s22010291. Acesso em: 10 de Janeiro de 2025.

JAKUBOWSKI, A.; KWIATKOWSKI, M.; NOWAK, M. Artificial Intelligence Approaches for Predictive Maintenance in the Steel Industry: A Survey. *Arxiv preprint*, arxiv:2405.12785, 2024. Disponível em: <<https://arxiv.org/abs/2405.12785>>. Acesso em: 10 de Janeiro de 2025.

JAKUBOWSKI, J. *et al.* Explainable anomaly detection for Hot-rolling industrial process. 2021b. Disponível em: <https://www.researchgate.net/publication/355460527_Explainable_anomaly_detection_for_Hot-rolling_industrial_process>. Acesso em: 10 de Janeiro de 2025.

JIANG, Y.; YIN, S. Recent results on key performance indicator oriented fault detection using the DB-KIT toolbox. In: *IECON 2017 - 43rd Annual Conference of the IEEE Industrial Electronics Society*. Beijing: IEEE, 2017. P. 7103–7108. Disponível em: <<http://ieeexplore.ieee.org/document/8217242/>>. Acesso em: 10 de Janeiro de 2025.

JIANG, Y., YIN, S., KAYNAK, O., 2021. Optimized Design of Parity Relation-Based Residual Generator for Fault Detection: Data-Driven Approaches. *IEEE Transactions on Industrial Informatics* 17, 1449–1458. URL: <<https://ieeexplore.ieee.org/document/9069263/>>, doi:10.1109/TII.2020.2987840. Acesso em: 10 de Janeiro de 2025.

JING, F.W. *et al.* Correlation analysis between looper system and strip width narrowing in hot strip rolling. *International Journal on Interactive Design and Manufacturing (ijidem)*, v. 17, p. 539–551, 2023. Disponível em: <<https://link.springer.com/10.1007/s12008-022-00940-y>>. Acesso em: 10 de Janeiro de 2025.

JIAO, R., PENG, K., DONG, J., 2021. Remaining Useful Life Prediction for a Roller in a Hot Strip Mill Based on Deep Recurrent Neural Networks. *IEEE/CAA Journal of Automatica Sinica* 8, 1345–1354. URL: <<https://ieeexplore.ieee.org/document/9444540/>>, doi:10.1109/JAS.2021.1004051. Acesso em: 10 de Janeiro de 2025.

JOUINI, O. *et al.* Digital twins for predictive maintenance: a systematic literature review. *Computers in Industry*, [S.l.], v. 118, p. 103230, 2020. Disponível em: <<https://doi.org/10.1016/j.compind.2020.103230>>. Acesso em: 10 de Janeiro de 2025.

JUNICHI, T.; YUKINORI, S. Condition Monitoring Technology for Steel Making Facilities Utilizing iot. *JFE Technical Report*, n. 25, p. 69–74, 2020. Disponível em: <<http://www.jfe-steel.co.jp/en/research/report/025/pdf/025-09.pdf>>. Acesso em: 10 de Janeiro de 2025.

KOVACIC, G. *et al.* Roll wear modeling using genetic programming. *Materials and Technology*, v. 53, n. 3, p. 379–384, 2019. Disponível em: <<https://mit.imt.si/izvodi/mit193/kovac.pdf>>. Acesso em: 10 de Janeiro de 2025.

KROT, P. *et al.* Model Based Monitoring of Dynamic Loads and Remaining Useful Life Prediction in Rolling Mills and Heavy Machinery. In: BALL, A. *et al.* (Org.). *Advances in Asset Management and Condition Monitoring*. Cham: Springer, 2020. P. 399–416. Disponível em: <http://link.springer.com/10.1007/978-3-030-57745-2_34>. Acesso em: 10 de Janeiro de 2025.

KUMAR, M.; DAS, A. Digital twin-driven predictive maintenance framework for cyber-physical systems. *Procedia Computer Science*, [S.l.], v. 218, p. 2394–2403, 2022. Disponível em: <<https://doi.org/10.1016/j.procs.2022.12.269>>. Acesso em: 10 de Janeiro de 2025.

KUMAR, R. *et al.* Barriers in implementation of Industry 4.0 in Indian manufacturing industries: An interpretive structural modeling approach. *Journal of Manufacturing Technology Management*, v. 31, n. 1, p. 177–193, 2020.

LEBRUN, C.A.V., CASTANEDA, R.S., ORTEGA, G.R., LOPEZ, J.M., VALD´EZ, J.L.C., MEDINA, H.F., 2013. Mathematical modelling of roll wear in a tandem mill hot strip rolling process. *International Journal of Mathematical Modelling and Numerical Optimisation* 4, 56. URL: <<http://www.inderscience.com/link.php?id=51334>>, doi:10.1504/IJMMNO.2013.051334. Acesso em: 10 de Janeiro de 2025.

LEONARDI, F. *et al.* Machine learning and reasoning for predictive maintenance in Industry 4.0: Current status and challenges. *Computers in Industry*, v. 123, p. 103298, 2020. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0166361520305327>>. Acesso em: 10 de Janeiro de 2025.

LI, X. *et al.* Industrial predictive maintenance with explainable artificial intelligence: A systematic literature review and future research directions. *Journal of Manufacturing Systems*, [S.l.], v. 68, p. 541–566, 2023. Disponível em: <<https://doi.org/10.1016/j.jmsy.2023.01.006>>. Acesso em: 10 Janeiro de 2025.

LI, L., DING, S.X.. Performance Supervised Fault Detection Schemes for Industrial Feedback Control Systems and their Data-Driven Implementation. *IEEE Transactions on Industrial Informatics* 16, 2849–2858, 2020. URL: <<https://ieeexplore.ieee.org/document/8827307/>>, doi:10.1109/TII.2019.2940099. Acesso em: 10 Janeiro de 2025.

MA, L., DONG, J., HU, C., PENG, K., 2021a. A novel decentralized detection framework for quality-related faults in manufacturing industrial processes. *Neurocomputing* 428, 30–41. URL: <<https://linkinghub.elsevier.com/retrieve/pii/S0925231220318385>,doi:10.1016/j.neucom.2020.11.045>. Acesso em: 10 Janeiro de 2025.

MA, T. *et al.* Fault Diagnosis of Laminar Cooling Roller Motor Based on Morphological Recognition and Combination Patterns Mining of Multicurrent Signatures. *IEEE Transactions on Instrumentation and Measurement*, v. 72, p. 1–15, 2023. Disponível em: <<https://ieeexplore.ieee.org/document/10059133/>>. Acesso em: 20 de Setembro de 2024.

MARCU, T., KOPPEN-SELIGER, B., STICHER, R., 2004. Hydraulic looper fault detection and isolation using dynamic neural networks, in: IFAC Automation in Mining. Mineral and Metal Processing, pp. 179–184. doi:10.1016/s1474-6670(17)31020-0. Acesso em: 20 de Setembro de 2024.

MARCU, T., KOPPEN-SELIGER, B., STICHER, R., 2008. Design of fault detection for a hydraulic looper using dynamic neural networks. *Control Engineering Practice* 16, 192–213. URL: <https://linkinghub.elsevier.com/retrieve/pii/S0967066106002218>, doi:10.1016/j.conengprac.2006.11.017. Acesso em: 20 de Setembro de 2024.

MARQUES, D. F. *et al.* Aplicação de Aprendizado de Máquina para a Predição de Falhas em Sistemas Hidráulicos de Laminadores. *Revista Engenharia e Pesquisa Aplicada*, v. 8, n. 1, p. 21–30, 2023.

PAN, J., CHEN, J., ZI, Y., YUAN, J., CHEN, B., HE, Z., 2016a. Data-driven monocomponent feature identification via modified nonlocal means and MEWT for mechanical drivetrain fault diagnosis. *Mechanical Systems and Signal Processing* 80, 533–552. URL: <<https://linkinghub.elsevier.com/retrieve/pii/S0888327016300905>>, doi:10.1016/j.ymssp.2016.05.013. Acesso em: 20 de Setembro de 2024.

PENG, R., ZHANG, X., SHI, P., 2022. Multi-Representation Domain Adaptation Network with Duplex Adversarial Learning for Hot-Rolling Mill Fault Diagnosis. *Entropy* 25, 83. URL: <https://www.mdpi.com/1099-4300/25/1/83>, doi:10.3390/e25010083. Acesso em: 20 de Setembro de 2024.

SANTOS, V. *et al.* Inteligência Artificial aplicada à manutenção preditiva em motores de corrente contínua: Estudo de caso em uma planta siderúrgica. *Revista de Engenharia Aplicada*, v. 11, n. 2, p. 55–68, 2022.

SARDA, K., ACERNESE, A., NOLE, V., MANFREDI, L., GRECO, L., GLIELMO, L., VECCHIO, C.D., 2021. A Multi-Step Anomaly Detection Strategy Based on Robust Distances for the Steel Industry. *IEEE Access* 9, 53827–53837. URL: <<https://ieeexplore.ieee.org/document/9393875/>>, doi:10.1109/ACCESS.2021.3070659. Acesso em: 20 de Setembro de 2024.

SILVA. *et al.* Desafios da Implementação da Manutenção Baseada em Dados em Laminadores de Aço. *Anais do Congresso Brasileiro de Engenharia de Fabricação*, v. 12, p. 88–95, 2021.

SILVA, M. A.; CUNHA, A. A. *Laminação: fundamentos e aplicações*. Rio de Janeiro: LTC, 2016.

SINGH, R.; GUPTA, A. Digital twin and machine learning for predictive maintenance in manufacturing systems: A review. *Journal of Manufacturing Systems*, [S.l.], v. 63, p. 157–169, 2022. Disponível em: <<https://doi.org/10.1016/j.jmsy.2022.01.010>>. Acesso em: 10 de Janeiro de 2025.

SONG, L. *et al.* Application of machine learning to predict and diagnose for hot-rolled strip crown. *The International Journal of Advanced Manufacturing Technology*, v. 120, p. 881–890, 2022. Disponível em: <<https://link.springer.com/article/10.1007/s00170-022-08825-w>>. Acesso em: 20 de Setembro de 2024.

TAO, Fei; ZHANG, Hui; LI, Ang; REN, Laili. Digital twin in industry: State-of-the-art. *IEEE Transactions on Industrial Informatics*, v. 15, n. 4, p. 2405–2415, 2019. Disponível em: <<https://doi.org/10.1109/TII.2018.2873186>> Acesso em: 10 de Janeiro de 2025.

THOMAS, John. The cost of maintenance in industrial production. *Journal of Industrial Engineering*, New York, v. 35, n. 2, p. 120–135, 2018.

TIENSUU, H.; HOLMBERG, K.; JOKINEN, L.; VARIS, J. Digitalization changing the innovation process in manufacturing industry. *Procedia Manufacturing*, [S.l.], v. 51, p. 995–1001, 2020. Disponível em: <<https://doi.org/10.1016/j.promfg.2020.10.139>>. Acesso em: 10 de Janeiro de 2025.

WANG, L.; PENG, Y. Modeling and Monitoring for Laminar Cooling Process of Hot Steel Strip Rolling with Time–Space Nature. *Processes*, v. 10, n. 3, p. 589, 2022. Disponível em: <<https://www.mdpi.com/2227-9717/10/3/589>>. Acesso em: 20 de Setembro de 2024.

WANG, X. *et al.* Digital twin-driven smart manufacturing: connotation, reference model, applications and research issues. *Robotics and Computer-Integrated Manufacturing*, [S.l.], v. 68, p. 102080, 2021. Disponível em: <<https://doi.org/10.1016/j.rcim.2020.102080>>. Acesso em: 20 de Setembro de 2024.

VELMURUGAN, R.; KUMAR, R.; KUMAR, A. Predictive maintenance of industrial equipment using machine learning and iot: a review. *Materials Today: Proceedings*, [S.l.], v. 80, p. 1573–1578, 2024. Disponível em: <<https://doi.org/10.1016/j.matpr.2023.09.151>>. Acesso em: 10 de Janeiro de 2025.

XIE, X. *et al.* Digital transformation and innovation performance: The mediating role of digital innovation capabilities. *Technological Forecasting and Social Change*, v. 166, 2021. DOI: <<https://doi.org/10.1016/j.techfore.2021.120632>> Acesso em: 20 de Setembro de 2024.

YUAN, L. *et al.* Fatigue-Damage Prediction Model of Backup Roll of Hot Strip Mills and its Applications. 2023. Disponível em: <https://www.researchgate.net/publication/369468428_FatigueDamage_Prediction_Model_of_Backup_Roll_of_Hot_Strip_Mills_and_its_Applications>. Acesso em: 10 de Janeiro de 2025.

ZHANG, W. *et al.* Data-driven methods for predictive maintenance of industrial equipment: A survey. *IEEE Systems Journal*, [S.l.], v. 13, n. 3, p. 2213–2227, 2020. Disponível em: <<https://doi.org/10.1109/JSYST.2019.2905565>>. Acesso em: 10 de Janeiro de 2025.

ZHANG, Y.; LI, Z. A digital twin-based approach for designing and implementing a cyber-physical production system. *Journal of Manufacturing Systems*, [S.l.], v. 58, p. 52–64, 2021. Disponível em: <<https://doi.org/10.1016/j.jmsy.2020.11.003>>. Acesso em: 10 de Janeiro de 2025.

MODELAGEM E CONTROLE PARA ESTABILIZAÇÃO DE UM QUADRIROTOR COM UM GRAU DE LIBERDADE

Pedro Henrique Col Carvalho

Universidade Tecnológica Federal do Paraná (UTFPR)

Leandro Castilho Brolin

Universidade Tecnológica Federal do Paraná (UTFPR)

Flávio Luiz Rossini

Universidade Tecnológica Federal do Paraná (UTFPR)

Marcelo Nanni

Universidade Tecnológica Federal do Paraná (UTFPR)

RESUMO

A busca por maior eficiência e competitividade impulsiona o desenvolvimento de novas tecnologias em diversas áreas. Nesse contexto, Veículo Aéreo Não Tripulado (VANT) tem sido amplamente utilizado. Este trabalho aborda a construção, identificação do sistema e controle de um VANT com um grau de liberdade, especificamente um quadrirotor. A identificação dos parâmetros do sistema segue a abordagem de caixa cinza, a qual aplicou-se para plantas com parâmetros desconhecidos. Para determinar esses parâmetros, utilizou-se o Método dos Mínimos Quadrados (MMQ), que possibilitou a descrição do comportamento dinâmico do protótipo. Com o modelo dinâmico identificado, o trabalho propõe-se a implementar de um controle moderno, especificamente em espaço de estados. Os resultados mostraram que o modelo matemático utilizado apresentou uma resposta apropriada às perturbações externas, portanto, assegurando a estabilidade e o retorno rápido a condição de operação.

palavras-chave: Quadrirotor; identificação de sistemas; servossistema do tipo 1; controle em espaço de estados.

INTRODUÇÃO

Os Veículos Aéreos Não Tripulados (VANTs) são definidos como veículos que utilizam forças aerodinâmicas para fornecer sustentação, podendo operar autonomamente ou serem pilotados remotamente (*Office of the Secretary of Defence*, 2008).

Entre suas classes, destacam-se os quadrirotores com um grau de liberdade, foco deste trabalho. Segundo Bouabdallah (2007), quadrirotores possuem quatro hélices dispostas em cruz, com dois pares girando em sentidos opostos para evitar o momento angular. Ao contrário dos helicópteros, não necessitam de um rotor de cauda, pois a alteração da velocidade angular dos pares de rotores permite modificar sua posição. Apesar de terem quatro atuadores, são sistemas dinamicamente instáveis (Bouabdallah, 2007; Li *et al.*, 2024).

A modelagem de quadrirotores é complexa, refletindo sua natureza instável e o desempenho dos motores. Assim, a estabilização requer um sistema de controle (Beard, 2008; Sheng *et al.*, 2022). Para facilitar a análise, é comum adotar simplificações como linearizações e exclusão de termos pouco relevantes (Beard, 2008). O principal desafio dos sistemas de controle está na complexidade do modelo matemático que descreve seu comportamento dinâmico.

Este estudo contribui para a compreensão e aplicação de uma técnica moderna de controle, baseada no espaço de estados, em sistemas instáveis como o quadrirotor. Assim, teve como objetivos:

- Desenvolver um protótipo de um quadrirotor com um grau de liberdade;
- Implementar o controle dos motores com uma plataforma embarcada;
- Aplicar o método dos mínimos quadrados para determinar os valores dos parâmetros das equações do protótipo no espaço de estados;
- Validar o modelo matemático do protótipo através de simulações computacionais utilizando o programa MATLAB;
- Construir a síntese de um controlador com o método de alocação de polos;

- Simular o sistema de controle em malha fechada no programa MATLAB;
- Implementar o sistema de controle em malha fechada na plataforma embarcada;
- Comparar as respostas teóricas e práticas do protótipo.

A metodologia começou pela identificação do modelo matemático do quadricóptero. Em seguida, utilizou-se o Método dos Mínimos Quadrados (MMQ) para identificar parâmetros, possibilitando a simulação em malha aberta no MATLAB. Após projetar o sistema de controle com realocação de polos, realizou-se a simulação e, por fim, a implementação no protótipo para comparar modelo teórico e prático (Carvalho, 2024).

O principal resultado foi a validação de que o modelo obtido estabiliza um sistema não linear e instável, com precisão de 61,57%. A principal contribuição consiste na implementação prática de um sistema de controle moderno, baseado no espaço de estados, aplicado a um sistema não linear e instável (Carvalho, 2024).

Este trabalho está estruturado da seguinte forma:

- Introdução: apresenta a contextualização, objetivos e metodologia da pesquisa;
- Quadricópteros: aborda a modelagem matemática que descreve o sistema;
- Metodologia: detalha os métodos utilizados para a identificação do sistema;
- Resultados: apresenta os resultados obtidos com o modelo teórico e prático;
- Discussão: discute os principais achados do estudo.


QUADRIROTORES

O quadrirotor utiliza quatro motores para locomover-se, a estrutura pode ser construída no formato $\times$ de + ou com um motor em cada extremidade. Cada motor tem uma hélice e o arranjo é feito de forma em que dois motores giram no sentido horário e dois no sentido anti-horário, o que reduz o torque gerado pela velocidade angular (SÁ, 2012).

Graus de liberdade

Um quadrirotor é composto por seis graus de liberdade, três são responsáveis pelas coordenadas de posição (x, y, z) e três pelos ângulos de orientação (θ, Φ, ψ) . Os ângulos de orientação são: *pitch*, *roll* e *yaw*, também conhecidos como ângulos de Euler (SÁ, 2012; EL HABBAL e ABDELKADER, 2021). Na Figura 1, apresenta-se o sistema de coordenadas.

Figura 1 - Sistema de coordenadas de um quadrirotor.



Fonte: adaptado de BEARD (2008).

Análise de forças, torque e momentos

O desenvolvimento das equações (1) a (17) corresponde ao apresentado por (BEARD, 2008). As principais forças do sistema são devido a gravidade, sendo possível assumir que as forças de empuxo e momentos aerodinâmicos

são insignificantes. Como se pode ver na Figura 1 cada motor produz uma força $\vec{F}$ e um torque $\vec{\tau}$. Portanto, a força total que atua no quadrirotor é dada por,

$$\vec{F}_T = \vec{F}_1 + \vec{F}_2 + \vec{F}_3 + \vec{F}_4 \quad (1)$$

sendo, $\vec{F}_T$ a força total aplicada ao quadrirotor e $\vec{F}_1, \vec{F}_2, \vec{F}_3$ e $\vec{F}_4$ as forças produzidas pelos Motores 1, 2, 3 e 4, respectivamente.

O torque $\vec{\tau}(\phi)$, responsável pelo ângulo *roll*, é produzido pela força dos Motores 2 e 4, aplicadas a uma distância do eixo de rotação, portanto,

$$\vec{\tau}(\phi) = l(\vec{F}_4 - \vec{F}_2) \quad (2)$$

Da mesma forma, o torque *pitch* $\vec{\tau}(\theta)$, produzido pelas forças dos Motores 1 e 3 é,

$$\vec{\tau}(\theta) = l(\vec{F}_1 - \vec{F}_3) \quad (3)$$

Segundo a terceira lei de Newton, o arrasto das hélices produz um torque yaw $\vec{\tau}(\psi)$ no corpo do quadrirotor. A direção desse torque é oposta à direção do movimento da hélice. Portanto, o torque total de *yaw* é dado por,

$$\vec{\tau}(\psi) = \vec{\tau}_2 + \vec{\tau}_4 - \vec{\tau}_1 - \vec{\tau}_3 \quad (4)$$

A sustentação e o arrasto produzidos pelas hélices são proporcionais ao quadrado da velocidade angular. Assumiu-se que a velocidade angular é diretamente proporcional ao sinal enviado ao motor. Portanto, a força e o torque de cada motor podem ser expressos como,

$$\vec{F}_i = k_1 \delta_i \quad (5)$$

$$\vec{\tau}_i = l k_2 \delta_i \quad (6)$$

Sendo k_1 e k_2 constantes que precisam ser determinadas experimentalmente, δ_i é o sinal de comando do motor e $i \in \{1, 2, 3, 4\}$ representa os índices dos Motores 1, 2, 3 e 4.

Portanto, as forças e torques no quadrirotor podem ser escritos como,

$$\begin{bmatrix} \vec{F_T} \\ \vec{\tau}(\phi) \\ \vec{\tau}(\theta) \\ \vec{\tau}(\psi) \end{bmatrix} = \begin{bmatrix} k_1 & k_1 & k_1 & k_1 \\ 0 & -lk_2 & 0 & lk_2 \\ lk_2 & 0 & -lk_2 & 0 \\ -k_2 & k_2 & -k_2 & k_2 \end{bmatrix} \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \end{bmatrix} \quad (7)$$

Além da força exercida pelos motores, a gravidade também exerce uma força sobre o quadrirotor. A força gravitacional que atua no centro de massa é dada por,

$$\vec{F_g} = \begin{bmatrix} 0 \\ 0 \\ m'g \end{bmatrix} \quad (8)$$

Sendo, $\vec{F_g}$ a força gravitacional, m' a massa total do quadrirotor e g a gravidade.

Os momentos de inércia do quadrirotor são calculados a partir de um centro esférico de raio R e massa m . Para representar os motores são consideradas massas pontuais M a uma distância l do centro. Como apresentado na Figura 1 o quadrirotor é simétrico, portanto, a inércia para cada uma das posições para uma esfera sólida mais as massas pontuais são dadas por,

$$J_x = \frac{2mR^2}{5} + 2l^2M \quad (9)$$

$$J_y = \frac{2mR^2}{5} + 2l^2M \quad (10)$$

$$J_z = \frac{2mR^2}{5} + 2l^2M \quad (11)$$

sendo, J_x , J_y e J_z os momentos de inércia em relação às posições x , y e z , respectivamente.

Modelo

O objetivo do modelo é ser utilizado para a construção de um sistema capaz de controlar a posição, a altitude e a direção do quadricóptero com base em medições em relação a uma posição alvo. A dinâmica do sistema é analisada no próprio referencial do quadricóptero. As equações apresentadas a seguir representam os seis graus de liberdade do sistema,

$$\ddot{x} = -\cos \phi \sin \theta \frac{\overrightarrow{F_T}}{m} \quad (12)$$

$$\ddot{y} = \sin \phi \frac{\overrightarrow{F_T}}{m} \quad (13)$$

$$\ddot{z} = g - \cos \phi \cos \theta \frac{\overrightarrow{F_T}}{m} \quad (14)$$

$$\ddot{\phi} = \frac{1}{J_x} \tau(\phi) \quad (15)$$

$$\ddot{\theta} = \frac{1}{J_y} \tau(\theta) \quad (16)$$


$$\ddot{\psi} = \frac{1}{J_z} \tau(\psi) \quad (17)$$

Sendo, $\ddot{x}$, $\ddot{y}$ e $\ddot{z}$ as acelerações lineares ao longo dos eixos x , y e z , respectivamente, e $\ddot{\phi}$, $\ddot{\theta}$ e $\ddot{\psi}$ as acelerações angulares ao longo desses mesmos ângulos. Na construção simplificada do protótipo escolheu-se como grau de liberdade a variável ângulo ϕ correspondente a Equação (15).

METODOLOGIA

Como primeiro passo do trabalho, construiu-se a estrutura física, cuja descrição é apresentada a seguir. A parte principal da estrutura é composta por duas peças de madeira: a base, com 420 mm de altura, e a barra principal, com 470 mm de comprimento. A barra é fixada no topo da base, e permite sua mobilidade no eixo horizontal, sua estrutura é construída de forma simétrica. O comprimento do centro de massa até o centro do motor é de $l = 210\text{ mm}$. Os motores *Brushless*, com massa $M = 67\text{ g}$ cada, são posicionados em cada extremidade da barra, que possui uma massa $m = 352\text{ g}$ e um raio $R = 235\text{ mm}$. Na Figura 2, apresenta-se uma foto do protótipo.

Figura 2 - Protótipo do quadrirotor com um grau de liberdade.



Fonte: Autoria própria (2024).


Com a finalização da construção do protótipo, foi possível realizar a análise do sistema de posicionamento, seguida pela identificação e implementação do controle da planta.

Arquitetura do protótipo

O circuito desenvolvido para o projeto tem como objetivo ler o valor do ângulo e a velocidade angular do sistema. Cabe ao microcontrolador processar essas informações e gerar o sinal de controle para cada motor.

Na Figura 3, apresenta-se o diagrama de blocos do sistema, com os componentes do sistema.

Figura 3 - Diagrama de blocos do protótipo.



Fonte: Autoria própria (2024).

Torque

Com base na Equação (2), pode-se determinar o torque produzido pelo quadrirotor. Portanto,

$$\vec{\tau}(\phi) = \vec{\tau}_4 - \vec{\tau}_2 \quad (18)$$

Sendo, $\vec{\tau}_4$ e $\vec{\tau}_2$ os torques produzidos pelos Motores 4 e 2, respectivamente. Assim o torque pode ser descrito como,

$$\vec{\tau}(\phi) = l(k'\delta_4 - k''\delta_2) \quad (19)$$

Onde, k' e k'' são as constantes a serem determinadas para os Motores 4 e 2, respectivamente.

Para determinar as constantes, considera-se a seguinte equação,

$$m_{empuxo}g = k\delta_i \quad (20)$$

Onde, $m_{empuxo}g$ representa o empuxo produzido pelo motor devido ao sinal de controle δ_i e k a constante a ser determinada.

Para determinar a relação k entre o empuxo e o sinal de controle, utilizou-se uma balança digital para medir o empuxo referente ao sinal de controle aplicado, sendo que para cada motor levantaram-se 11 pontos.

Fixou-se o motor a um peso, que por sua vez foi conectado à balança, por meio de fita dupla face. O objetivo de utilizar o peso era para compensar o empuxo gerado pelo motor. Na Figura 4, ilustra-se o processo de medição do empuxo gerado pelos motores.

Figura 4 - Medição do empuxo gerado pelos motores.



Fonte: Autoria própria (2024).

Modelo em espaço de estados

Diferente do controle clássico que é fundamentado na relação entrada-saída, o controle moderno utiliza notação vetorial-matricial com o intuito de simplificar o sistema de equações, esse sistema é descrito em n -ésimas equações diferenciais de primeira ordem (OGATA, 2010).

O modelo no domínio do espaço de estados é representado como,

$$\dot{x}(t) = Ax(t) + Bu(t) \quad (21)$$

$$y(t) = Cx(t) \quad (22)$$

Sendo, $x(t)$ o vetor de estados, $\dot{x}(t)$ a derivada temporal do vetor de estados, $y(t)$ o vetor de saída, $u(t)$ o vetor de entrada, A a matriz de transição do sistema, B a matriz de entrada e C a matriz de saída.

O protótipo construído para o presente trabalho avalia apenas o ângulo ϕ . Ao considerar que a aceleração angular $\ddot{\phi} = \frac{1}{J_x} \tau(\phi)$ relaciona os sinais de controle com a velocidade angular, substituiu-se a Equação (19) na Equação (16),

$$\ddot{\phi} = \frac{1}{J_x} l(k'\delta_4 - k''\delta_2) \quad (23)$$

Assim, as variáveis de estados são definidas como,

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = \ddot{\phi} \end{cases} \quad (24)$$

Sendo, x_1 a variável de estados que representa o ângulo de rotação ϕ e x_2 referente a velocidade angular $\dot{\phi}$.

Dessa forma, na Equação (23), tem-se

$$\dot{x}_2 = \frac{1}{J_x} l(k'\delta_4 - k''\delta_2) \quad (25)$$

Ao reorganizar, obtém-se

$$\dot{x}_2 = \frac{1}{J_x} l k' \delta_4 - \frac{1}{J_x} l k'' \delta_2 \quad (26)$$

Assim, o modelo no espaço de estados é representado por,

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 & 0 \\ \frac{l k'}{J_x} & -\frac{l k''}{J_x} \end{bmatrix} \begin{bmatrix} \delta_4 \\ \delta_2 \end{bmatrix} \quad (27)$$

A saída do sistema para o ângulo ϕ , é dada por,

$$y = \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (28)$$

É importante destacar que o sistema de um quadrirotor é intrinsecamente instável e não linear, com ambos os polos situados na origem. No entanto, para o presente projeto, simplificou-se o modelo para fins de estudo, sendo linearizado em torno do ponto de equilíbrio, correspondente ao ângulo zero.

RESULTADOS


A área de identificação de sistemas dinâmicos tem se mostrado essencial no desenvolvimento de estratégias de controle. Nesse contexto, métodos de estimação de parâmetros, como o Método dos Mínimos Quadrados (MMQ), têm sido aplicados por permitirem descrever a dinâmica da planta com base em dados experimentais. Os seguintes trabalhos recentes demonstram a eficácia de tal método de identificação de sistemas:

- ROSSINI (2020) apresentou o Método dos Mínimos Quadrados Recursivo aplicado a sistemas de teleoperação bilateral;
- CANHAN; BROLIN; ROSSINI (2023) analisaram o desempenho de algoritmos de estimação paramétrica aplicados ao controle adaptativo por modelo de referência;
- COLDEBELLA; ROSSINI (2023a) demonstraram a aplicação do MMQ com fator de esquecimento no projeto e simulação de um sistema adaptativo com ajuste de ganho dinâmico.

O presente trabalho utilizou o Método dos Mínimos Quadrados (MMQ) para determinar os parâmetros que relacionam o sinal de controle enviado aos motores com o torque por eles gerado. Para medir o empuxo de cada motor, realizou-se a rotina de teste.

No caso do Motor 4, o sinal de controle foi ajustado gradativamente, enquanto o empuxo correspondente era medido. Para o Motor 2, o sinal de controle foi reduzido, seguindo o mesmo procedimento de medição. A manipulação do sinal de controle consistiu na variação de um valor numérico entre 1200 e 1400, enviado por meio da função da biblioteca <Servo.h> do Arduino, que, internamente, realiza o acionamento do motor por meio de um sinal de modulação por largura de pulso, do inglês *Pulse Width Modulation* (PWM). Para cada motor, foram coletadas 30 amostras em cada um dos 11 pontos definidos, e a média dessas amostras foi calculada. A Figura 5 ilustra a curva obtida para os Motores 4 e 2.

Figura 5 - Curva de resposta dos motores em função do sinal PWM.



Fonte: Autoria própria (2024).

Para determinar a linha de ajuste e os coeficientes de cada sinal, utilizou-se a função `polyfit()` do MATLAB.

Ao calcular o coeficiente angular das retas de ajuste, obtém-se que $k' = 4,0266$ para o Motor 4 e $k' = 4,6731$ para o Motor 2. Portanto, determinaram-se as constantes que relacionam o sinal de controle aplicado e o empuxo de cada

motor. Destaca-se que foram desprezadas as dinâmicas dos motores, uma vez que estas são significativamente mais rápidas quando comparadas com o sistema completo. Essa abordagem segue métodos tradicionais de identificação de sistemas, que consideram modelos simplificados para facilitar a análise e controle do sistema (AGUIRRE, 2004).

Momento de inércia

Devido a simetria da estrutura do protótipo, o momento de inércia é o mesmo para os três eixos, $J_x = J_y = J_z$. Ao aplicar os dados da estrutura do protótipo na Equação (10), obtém-se,

$$J_x = 0,0137 \text{ Kg.m}^2$$

Resposta em malha aberta

Ao substituir os parâmetros calculados, referentes ao torque e momento de inércia, no modelo em espaço de estados Equação (27), obtém-se o seguinte modelo em espaço de estados para o sistema simplificado que representa parcialmente o comportamento do quadrirotor,


$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 & 0 \\ 61,79 & -71,71 \end{bmatrix} \begin{bmatrix} \delta_4 \\ \delta_2 \end{bmatrix} \quad (29)$$

Com a saída do sistema para o ângulo ϕ ,

$$y = \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (30)$$

Os polos do sistema simplificado do quadrirotor estão localizados na origem do plano complexo, isto significa que o sistema não tem a capacidade inerente de retornar ao equilíbrio após uma perturbação. Na Figura 6, ilustra-se esse comportamento,

Figura 6 - Resposta em malha aberta.



Fonte: Autoria própria (2024).

Foi aplicado um sinal em degrau ao modelo em malha aberta, o que resultou em um comportamento quadrático, compatível com a resposta esperada de um sistema de segunda ordem com dois polos na origem, conforme apresentado na Figura 6.

Escolha dos polos desejados

Para a sintonia do controlador, o primeiro passo é determinar os polos desejados. Para estabilizar rapidamente, definiu-se um tempo de estabelecimento T_s de 0,3 segundos e um sobressinal M_p de 1% para a determinação dos polos desejados.

A relação entre o sobressinal e o coeficiente de amortecimento ζ é dada por: $M_p = \frac{-\pi\zeta}{e^{\sqrt{1-\zeta^2}}}$. Além disso, o tempo de estabelecimento pode ser aproximado

por: $T_s \approx \frac{4}{\zeta\omega_n}$ (OGATA, 2010).

A partir dos parâmetros definidos e com um sistema de segunda ordem subamortecido, ao calcular o coeficiente de amortecimento obtém-se, $\zeta = 0,8261$ e para a frequência natural $\omega_n = 16,1404 \text{ rad/s}$.

Ao aplicar os parâmetros obtidos, os polos desejados são,

$$\begin{aligned} p_1 &= -13,3333 + 9,0958j \\ p_2 &= -13,3333 - 9,0958j \end{aligned}$$

Sendo, p_1 e p_2 um par conjugado complexo, e representa a unidade imaginária.

Os polos encontrados indicam que o novo modelo terá uma resposta oscilatória amortecida para uma entrada em degrau, assim projetou-se o sistema para ter uma resposta rápida com o retorno estável após perturbações.

Alocação de polos

Com os polos desejados calculados é possível aplicar a técnica de alocação de polos. Para determinar a matriz de ganho K responsável pela realimentação de estados, utilizou-se a função *place()*, o que permite posicionar os polos de forma a ajustar o comportamento do sistema conforme desejado.

$$K = \begin{bmatrix} 1,7965 & 0,1839 \\ -2,0849 & -0,2134 \end{bmatrix} \quad (31)$$

Sistema de controle

Neste trabalho, projetou-se um servossistema do tipo 1 quando a planta possui um integrador. O objetivo desse sistema é garantir que a saída rastreie uma referência desejada, mesmo na presença de distúrbios. Quando um distúrbio é aplicado, a saída desviará da referência, e o sistema atua para minimizar o erro (OGATA, 2010).

Com base no modelo representado na Equação (21), pode-se definir o sinal de controle como,

$$u(t) = -K x(t) + k_1 r \quad (32)$$

Sendo, $u(t)$ o sinal de controle, K a matriz de ganho, k_1 o primeiro elemento de K e r o sinal de referência. A Equação (32) é conhecida como realimentação de estados.

Ao substituir a Equação (32) na Equação (23), obtém-se,

$$\dot{x}(t) = (A - BK) x(t) + Bk_1r \quad (33)$$

Como os autovalores da matriz A são os polos do sistema, dessa forma, ajustar a matriz K corretamente fará com que a matriz $(A - BK)$ torne o sistema assintoticamente estável, fazendo que a saída se torne igual a referência r (OGATA, 2010).

Com a alocação de polos realizada, torna-se possível determinar a nova matriz de estados,

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 \\ -260,5 & -26,67 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} 0 \\ 260,5 \end{bmatrix} r \quad (34)$$


Com a saída do sistema para o ângulo ϕ ,

$$y = \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (35)$$

Resposta em malha fechada

Com a realimentação de estados, ao aplicar a mesma entrada aplicada no teste em malha aberta, ajustou-se o comportamento do sistema de malha fechada para atender as especificações definidas. Na Figura 7, apresenta-se o comportamento do sistema,

Figura 7 - Resposta em malha fechada.



Fonte: Autoria própria (2024).

Os polos encontrados indicam que o sistema apresenta uma resposta adequada a uma entrada em degrau, o que garante a estabilidade e um retorno rápido à condição de operação. Ao utilizar a função *stepinfo()*, obtém-se um sobressinal de 1% e um tempo de estabelecimento de 0,2461 segundos.

Lei de controle

Para determinar a lei de controle, substituíram-se as variáveis no modelo discreto, resultando no seguinte modelo no tempo discreto,

$$\begin{bmatrix} \delta_4(t_d) \\ \delta_2(t_d) \end{bmatrix} = -K \begin{bmatrix} \phi(t_d) \\ \dot{\phi}(t_d) \end{bmatrix} + k_1 r \quad (36)$$

Sendo, $\delta_4(t_d)$ e $\delta_2(t_d)$ os sinais de controle no tempo discreto aplicados aos Motores 4 e 2, respectivamente, $\phi(t_d)$ o ângulo de rotação no tempo discreto e $\dot{\phi}(t_d)$ a velocidade angular no tempo discreto.

Ao subsistir a matriz K na Equação (36),

$$\begin{bmatrix} \delta_4(t_d) \\ \delta_2(t_d) \end{bmatrix} = - \begin{bmatrix} 1,7965 & 0,1839 \\ -2,0849 & -0,2134 \end{bmatrix} \begin{bmatrix} \phi(t_d) \\ \dot{\phi}(t_d) \end{bmatrix} + \begin{bmatrix} 1,7965 \\ -2,0849 \end{bmatrix} r \quad (37)$$

Assim, o sinal de controle correspondente ao Motor 4 é dado por,

$$\delta_4(t_d) = -1,7965\phi(t_d) - 0,1839\dot{\phi}(t_d) + 1,7965r \quad (38)$$


E para o Motor 2 o sinal de controle é,

$$\delta_2(t_d) = 2,0849\phi(t_d) + 0,2134\dot{\phi}(t_d) - 2,0849r \quad (39)$$

Comparação entre o modelo teórico e os dados experimentais

Com a lei de controle implementada no sistema embarcado, aplicaram-se distúrbios manuais ao protótipo para verificar sua capacidade de reestabelecer a condição de equilíbrio. Na Figura 8, ilustra-se tal comportamento.

Figura 8 - Resposta do protótipo a distúrbios manuais.




Fonte: Autoria própria (2024).

Como pode ser observado na Figura 8, distúrbios foram aplicados ao sistema: o primeiro, antes dos 5 segundos, e o segundo, próximo dos 10 segundos. Mesmo assim, o sistema manteve a estabilidade e controlou a saída em torno do ângulo de referência igual a zero.

Para a validação do modelo, aplicou-se um sinal pseudoaleatório, tendo uma amplitude de 25°. Ao utilizar a função *compare()*, compara-se o modelo em espaço de estados discreto com os dados obtidos experimentalmente, e

calcula-se o erro quadrático médio normalizado (NRMSE) entre as saídas previstas pelo modelo e os valores medidos. Na Figura 9, ilustra-se a comparação entre a resposta simulada e os dados experimentais,

Figura 9 - Resposta ao sinal r.



Fonte: Autoria própria (2024).

Os resultados indicam que, com base na análise da função *compare()*, o protótipo apresentou uma precisão de 61,75%. Apesar do tempo de estabelecimento estar conforme projetado, o sistema apresenta um sobressinal significativamente superior ao esperado, o que impacta negativamente na precisão. Além disso, o sinal de ângulo apresentou ruído e um deslocamento próximo a 5 graus em relação ao ângulo zero, o que também afetou o desempenho do sistema.

Uma possível causa da diferença entre o modelo teórico e o comportamento experimental está na natureza não linear do sistema. Durante a identificação do sistema, foi adotado um modelo linear com dois polos na origem, e mesmo com os dois integradores na planta, o protótipo apresentou um erro em regime permanente.

O comportamento indesejado no regime permanente foi o deslocamento em 5 graus quando o referencial é configurado em zero grau. Esse fenômeno não ocorre quando a referência está com ângulos positivos. Uma possível


explicação para esse comportamento é a não simetria perfeita da estrutura ou a falta de não simetria na lei de controle, conforme descrita na Equação (37).

Para uma primeira aproximação do modelo, os resultados obtidos foram satisfatórios em termos práticos. Mesmo ao considerar as limitações encontradas, o desempenho do protótipo indicou ser eficaz para o controle do sistema, evidenciando a viabilidade da abordagem proposta.

Análise experimental do protótipo ao degrau

Com objetivo de comparar o desempenho do sistema de controle teórico e prático, aplicou-se um sinal degrau com o ângulo de 25 graus no protótipo e analisaram-se os dados obtidos. Na Figura 10, ilustra-se a resposta do protótipo ao degrau.

Figura10 - Resposta do protótipo ao degrau.



Fonte: Autoria própria (2024).

Para determinar o sobressinal e o tempo de pico, utilizou-se a função *stepinfo()*. Devido ao ruído presente no sistema real, adotou-se uma aproximação para o tempo de estabelecimento por meio da constante de tempo. Esse parâmetro foi estimado observando-se o tempo para o sistema atingir

63,33% do valor em regime permanente. Esse valor foi multiplicado por quatro, resultando em uma aproximação do tempo de estabelecimento. No Quadro 1, apresentam-se os resultados obtidos.

Quadro 1 - Comparação das Características da Resposta ao Degrau.

	Resposta Teórica	Resposta Prática
Polos em Malha Aberta	0 0	-
Polos em Malha Fechada	-13,3333 + 9,0958j -13,3333 - 9,0958j	-
Tempo de estabelecimento (s)	0,2461	1,36
Tempo de Pico (s)	0,3454	0,6100
Sobressinal (%)	1	50,0456

Fonte: Autoria própria (2024).

Observa-se que na reposta experimental apresenta um sobressinal significativamente superior à reposta teórica. Além disso, os tempos de resposta do sistema, como tempo de estabelecimento e o tempo de pico, também foram superiores ao projetado. É possível modificar a resposta do sistema através da escolha dos polos: polos mais afastados do eixo imaginário resultam em respostas mais rápidas, enquanto polos mais afastados do eixo real aumentam o sobressinal. Para uma primeira aproximação do modelo, o sistema prático apresentou uma resposta satisfatória, corrigindo o ângulo de acordo com o referencial adotado. A escolha dos polos foi realizada de forma a proporcionar uma resposta rápida, sem que o sinal de controle sofresse saturação.

DISCUSSÃO

Este trabalho teve como objetivo a identificação, análise e controle de um quadricóptero com um grau de liberdade, para o qual foi desenvolvido um protótipo. Os componentes selecionados para a construção do protótipo atenderam aos requisitos estabelecidos no escopo do projeto, os quais permitiram a identificação e modelagem do sistema, o que possibilitou a aplicação da técnica de controle e a avaliação de modelo.

A modelagem do protótipo revelou-se o maior desafio do trabalho, devido à dificuldade em representar o sistema de modo satisfatório. Acredita-se que, sem as simplificações aplicadas ao modelo, o sistema poderia alcançar uma precisão maior. Contudo, o controle em espaço de estados proposto demonstrou bons resultados na estabilização e no posicionamento do ângulo roll, com sua eficácia sendo verificada nos testes realizados.

A implementação do sistema de controle ocorreu sem dificuldades, o que permitiu a observação do comportamento esperado nos testes, com um resultado de 61,57% de precisão na validação do modelo, e no levantamento dos parâmetros restantes por meio do método dos mínimos quadrados.

O *script* desenvolvido no MATLAB permitiu a simulação do sistema em malha aberta, Equações (29) e (30), e em malha fechada, Equações (34) e (35), além de possibilitar a síntese da alocação de polos, Equação (31) e determinar a lei de controle, Equação (37). Também se tornou possível a validação do método teórico com o prático.

Como direcionamento para trabalhos futuros, busca-se explorar outras técnicas, como as de controle adaptativo, a fim de comparar os resultados obtidos e identificar a técnica que apresente o melhor desempenho. Além disso, recomenda-se projetar um filtro para a redução do ruído no sinal do ângulo, com o objetivo de melhorar o desempenho do sistema. Como avaliação futura, realizará um ajuste fino para reduzir o sobressinal e avaliar as dinâmicas desprezadas no modelo. Outra proposta é a construção de um sistema com dois graus de liberdade, o que permitirá a implementação completa de um sistema de estabilidade e posicionamento do quadrirotor.

REFERÊNCIAS

- AGUIRRE, L. A. Introdução à identificação de sistemas: técnicas lineares e não lineares aplicadas a sistemas reais. Belo Horizonte: Editora UFMG, 2004.
- BEARD, R. Quadrotor dynamics and control. Provo: Brigham Young University, 2008.
- BOUABDALLAH, S. Design and control of quadrotors with application to autonomous flying. 2007. 155 f. Tese (Doutorado em Ciências) – Escola Politécnica Federal de Lausanne, Lausanne, 2007.

CANHAN, Diego Carrião; BROLIN, Leandro Castilho; ROSSINI, Flávio Luiz. Projeto e Análise de Desempenho de Algoritmos de Estimação Paramétrica Aplicados ao Controle Adaptativo por Modelo de Referência. *In: SOARES, A. M. Tópicos Especiais em Engenharia: inovações e avanços tecnológicos* 6. Ponta Grossa: Aya, 2023. p. 42-54. ISBN 9786553792555.

CARVALHO, P. H. C. Construção, identificação, controle e análise de sistemas de estabilidade e posicionamento de um quadrirotor com um grau de liberdade: estudo de caso. 2024. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Eletrônica) – Universidade Tecnológica Federal do Paraná, Campo Mourão, 2024.

COLDEBELLA, Henrique; ROSSINI, Flávio Luiz. Design and Simulation of a Model Reference Adaptive Control System Using the Recursive Least Squares Method with Forgetting Factor for Gain Adjustment. *In: Seven Editora. Development and Its Applications in Scientific Knowledge*. São José dos Pinhais: Seven Editora, 2023. p. 3499-3515. ISBN 978-65-84976-28-3.

EL HABBAL, Mohamed A.; ABDELKADER, Mohamed. Quadcopter UAV Modeling and Control: A Linear State Space Approach. *IEEE Access*, v. 9, p. 51603–51614, 2021.

OFFICE OF THE SECRETARY OF DEFENSE. Unmanned aircraft systems roadmap, 2005-2030. Washington, D.C.: Department of Defense, 2008.

OGATA, K. Engenharia de controle moderno. 5. ed. São Paulo: Pearson Hall, 2010.

ROSSINI, Flávio Luiz. Métodos de Filtragem, Estimação e Controle Adaptativo Indireto Aplicados a Sistemas de Teleoperação Bilateral. pt. PhD thesis. Faculdade de Engenharia Elétrica e de Computação – Universidade Estadual de Campinas, 2020, p. 92.

SÁ, R. C. Construção, modelagem e controle PID para estabilidade de um veículo aéreo não tripulado do tipo quadrirotor. 2012. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Ceará, Fortaleza, 2012.

Sheng, H., Zhang, C., & Xiang, Y. (2022). Mathematical Modeling and Stability Analysis of Tiltrotor Aircraft. *Drones*, 6(4), 92.

Li, X., Qi, G., & Zhang, L. (2024). Control Stability Analysis of Dynamic Model with Time Delay for Quadrotor UAV. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*.

ESTUDO DE CASO COM MODELAGEM DA CINEMÁTICA DIRETA E INVERSA ANALÍTICA DO ROBÔ ABB IRB 1010 E VALIDAÇÃO VIA SIMULAÇÃO

Gabriel Pitondo Rossini

Universidade Tecnológica Federal do Paraná (UTFPR)

Otávio Amaro de Paula dos Santos

Universidade Tecnológica Federal do Paraná (UTFPR)

Flávio Luiz Rossini

Universidade Tecnológica Federal do Paraná (UTFPR)

RESUMO

Este artigo apresenta um estudo de caso voltado à análise da cinemática de um manipulador robótico de seis graus de liberdade, com foco na dedução analítica da cinemática inversa e sua verificação por meio de simulação computacional. O robô industrial ABB IRB 1010 foi selecionado como modelo de referência, sendo inicialmente analisado por meio de transformações homogêneas para obtenção da cinemática direta. A cinemática inversa foi então resolvida de forma analítica, permitindo a determinação explícita dos ângulos articulares necessários para atingir uma configuração desejada. Como parte do estudo de caso, definiu-se uma posição e orientação alvo para o efetuador final, e os resultados da solução analítica foram utilizados para gerar uma trajetória suave por interpolação polinomial cúbica. A trajetória foi implementada e simulada nos ambientes MATLAB® Simulink e Simscape Multibody, permitindo a validação numérica e visual do modelo. Os resultados obtidos confirmam a coerência entre a formulação teórica e o comportamento simulado do robô, demonstrando a eficácia da abordagem analítica proposta para aplicações práticas em automação industrial.


Palavras-chave: Cinemática direta; cinemática inversa; robô IRB ABB 1010; simulação.

INTRODUÇÃO

Desde os primórdios da ficção científica, a figura do robô tem povoado o imaginário humano. Isaac Asimov, um dos mais populares escritores do século XX, postulou as Três Leis da Robótica, um código de conduta para reger a interação entre humanos e máquinas (ASIMOV, 1950). Na obra, os robôs continuamente realizam tarefas complexas e, por diversas vezes, assumem responsabilidades antes delegadas a humanos.

O que antes era apenas imaginação, hoje rapidamente se torna realidade. Atualmente, o campo da robótica está em rápida ascensão, com cerca de 4 milhões de robôs em operação na indústria em 2023, como mostra a Figura 1. Nesse contexto de crescente complexidade, a capacidade de controlar com precisão e rapidez o movimento de robôs torna-se fundamental.

Figura 1 - Robôs industriais em operação no mundo.



Fonte: International Federation of Robotics.

Portanto, a cinemática inversa, que busca determinar as configurações das juntas necessárias para alcançar uma determinada posição e orientação do efetuador final de um robô, desempenha um papel crucial nesse processo.

A cinemática inversa pode ser abordada por duas técnicas principais: a analítica e a numérica. Enquanto a solução numérica se baseia em algoritmos iterativos para aproximar as configurações das juntas (ABREU *et al.*, 2023; CRAIG, 2012; REZENDE; ROSSINI, 2023), a solução analítica busca equações fechadas

que fornecem as soluções exatas (REZENDE; ROSSINI, 2024; ABREU *et al.*, 2023; FUDOLI *et al.*, 2016; PENHA *et al.*, 2016), baseada na cinemática direta (SOUZA *et al.*, 2023). Ambas as abordagens, são aplicáveis ao controle de robô manipuladores (PONTIM *et al.*, 2025; TAKANO; ROSSINI, 2024; ROSSINI *et al.*, 2023; BARROZO; ROSSINI, 2023). Contudo, fica a critério do engenheiro projetista do robô escolher a abordagem da inversa aplicada à estratégia de controle não linear, uma vez que métodos iterativos demandam de maior esforço computacional (ROSSINI *et al.*, 2023; ROSSINI *et al.*, 2022; LIMA *et al.*, 2022; ROSSINI *et al.*, 2023). Apesar da existência de diversos métodos numéricos, a solução analítica se mostra mais eficiente em termos de tempo de processamento, o que a torna crucial para aplicações em tempo real (SANCHES; ROSSINI, 2016).


Este artigo apresenta um estudo de caso completo envolvendo o robô industrial ABB IRB 1010, com o objetivo de desenvolver sua cinemática direta e inversa de forma analítica (LYNCH; PARK, 2017), bem como verificar a consistência desses modelos por meio de simulação computacional utilizando MATLAB® Simulink e MATLAB® Simscape. A análise inicia-se com a definição dos sistemas de coordenadas associados às juntas do robô e a aplicação de transformações homogêneas para obtenção da matriz do efetuador final, resultando em uma modelagem cinemática direta. Em seguida, é realizada a dedução analítica da cinemática inversa, abordando separadamente os problemas de posicionamento e orientação, e considerando a multiplicidade de soluções possíveis.

ABB IRB 1010

Desenvolvido pela multinacional suíça ABB, o ABB IRB 1010 é o menor robô industrial de seu portfólio, projetado especificamente para atender às demandas da produção de eletrônicos miniaturizados. Este manipulador compacto oferece desempenho notável, com carga útil de 1,5 kg, repetibilidade de 0,01 mm e dimensões 30% menores em relação a outros robôs industriais da mesma categoria.

Com 6 graus de liberdade (6-DOF), o manipulador possui 6 juntas rotativas que lhe conferem a capacidade de mover-se em três dimensões e orientar sua ferramenta de forma irrestrita. A Figura 2 (b) detalha como cada junta se movimenta.

Figura 2 - Descrição do robô ABB IRB 1010.



(a) Construção Física

(b) Movimento das juntas

Fonte: Product specification IRB 1010.

CINEMÁTICA DIRETA

A cinemática direta tem como objetivo primordial determinar a posição e orientação precisas do efetuador final de um manipulador robótico. Essa determinação é feita em referência a um sistema de coordenadas fixo, utilizando como dados de entrada os ângulos de cada uma das juntas do robô. Para tanto, cada junta deve ser associada a um sistema de coordenadas, representado por uma transformada homogênea, descrito em termos do sistema de coordenadas da junta precedente (SANCHES; ROSSINI, 2016).

A transformada ${}^A_B T$ é composta por uma matriz de rotação ${}^A_B R$ que representa a orientação da junta B em relação à junta anterior A , e um vetor de posição que indica a origem de B em relação a A , ${}^A P_{BORG}$. Logo, a transformada homogênea de B em relação a A é então retratada pela Equação (1).

$${}^A_B T = \begin{bmatrix} {}^A_B R & {}^A P_{BORG} \\ 0 & 1 \end{bmatrix} \quad (1)$$


Através da multiplicação sucessiva de cada transformação de cada junta, é possível obter a matriz de transformação final, que representa a posição e orientação do efetuador final em relação ao sistema de coordenadas de referência.

Dado que o robô em análise possui seis juntas rotativas, são necessárias seis transformações homogêneas ${}^i_{i-1}T$ para descrever sua cinemática direta, conforme demonstrado na Equação (2).

$${}^0_6T = {}^0_1T {}^1_2T {}^2_3T {}^3_4T {}^4_5T {}^5_6T \quad (2)$$

Na Figura 3, ilustram-se os sistemas de coordenadas utilizados, nos quais todas as rotações são definidas em torno do eixo Z seguindo a regra da mão direita. As Equações de (3) a (7) detalham as transformações homogêneas resultantes do processo de modelagem cinemática. Nota-se que $c_n = \cos(\theta_n)$ e $s_n = \sin(\theta_n)$. O sistema de referência fixo foi arbitrado como demonstra a Figura 3.

Figura 3 - Descrição dos eixos de rotação do robô.



Fonte: Autoria própria (2025).

O primeiro sistema de coordenadas tem a mesma orientação do sistema fixo e está deslocado em d_1 unidades ao longo do eixo Z_0 . Assim, a transformada homogênea 0_1T é dada pela Equação (3).

$${}^0_1T = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & d_1 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} c_1 & -s_1 & 0 & 0 \\ s_1 & c_1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} c_1 & -s_1 & 0 & 0 \\ s_1 & c_1 & 0 & 0 \\ 0 & 0 & 1 & d_1 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3)$$

Para a definição do segundo sistema de coordenadas, adota-se uma rotação que reorienta os eixos do sistema anterior com base na seguinte correspondência: X_2 na direção de Z_1 , Y_2 na direção de X_1 e Z_2 na direção de Y_1 . Essa orientação indica uma rotação tridimensional em que os eixos do sistema 2 são obtidos por uma permutação dos eixos do sistema 1, associada ao movimento relativo da junta 2 em relação à junta 1. Portanto, a transformada homogênea 1_2T é descrita conforme Equação (4).

$${}^1_2T = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & d_2 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} c_2 & -s_2 & 0 & 0 \\ s_2 & c_2 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} s_2 & c_2 & 0 & 0 \\ 0 & 0 & 1 & d_2 \\ c_2 & -s_2 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4)$$

Assim como o primeiro sistema de coordenadas, o terceiro está alinhado com o seu antecessor, mas deslocado em d_3 unidades ao longo de X_2 . Consequentemente, 2_3T é dada pela Equação (5).

$${}^2_3T = \begin{bmatrix} 1 & 0 & 0 & d_3 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} c_3 & -s_3 & 0 & 0 \\ s_3 & c_3 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} c_3 & -s_3 & 0 & d_3 \\ s_3 & c_3 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (5)$$

O quarto sistema tem X_4 na direção de Z_3 , Y_4 na de X_3 e Z_4 na de Y_3 . Além disso, está deslocado de d_4 em Y_3 . Logo, 3_4T é descrita em consonância com a Equação (6).

$${}^3_4T = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & d_4 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} c_3 & -s_3 & 0 & 0 \\ s_3 & c_3 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} s_4 & c_4 & 0 & 0 \\ 0 & 0 & 1 & d_4 \\ c_4 & -s_4 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (6)$$

O quinto sistema de coordenadas está orientado conforme a Figura 3 e é descrito pela Equação (7).

$${}^4_5T = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & d_5 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} c_3 & -s_3 & 0 & 0 \\ s_3 & c_3 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ c_5 & -s_5 & 0 & 0 \\ s_5 & c_5 & 0 & d_5 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (7)$$

O sexto sistema é descrito através da Equação (8).

$${}^5_6T = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & d_6 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} c_3 & -s_3 & 0 & 0 \\ s_3 & c_3 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} s_6 & c_6 & 0 & 0 \\ 0 & 0 & 1 & d_6 \\ c_6 & -s_6 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (8)$$

A escolha de posicionar as origens dos três últimos eixos de forma coincidente, conforme observado, visa simplificar a solução da cinemática inversa sem afetar a cinemática direta. Dessa maneira, apenas os três primeiros eixos afetam a posição final do modelo.

Entretanto, essa abordagem faz com que o último eixo não esteja no ponto final do manipulador. Todavia, a posição desse ponto pode ser facilmente determinada através da Equação (9), considerando a distância de 45 mm ao longo do eixo Z_6 . A orientação, por sua vez, coincide com a do último eixo.

$$P = {}^0_6T \begin{bmatrix} 0 \\ 0 \\ 45 \\ 0 \end{bmatrix} \quad (9)$$

Os parâmetros d_1 a d_6 , bem como a faixa de movimento permitida para cada uma de suas juntas, estão detalhados na Tabela 1.

Tabela 1 - Tabela de restrições.


Eixos	Distância	Faixa de operação
Eixo 1: d_1 e θ_1	190mm	$\pm 170^\circ$
Eixo 2: d_2 e θ_2	0	- 75° /+ 125°
Eixo 3: d_3 e θ_3	185mm	- 180 /+ 170°
Eixo 4: d_4 e θ_4	185mm	$\pm 170^\circ$
Eixo 5: d_5 e θ_5	0	$\pm 125^\circ$
Eixo 6: d_6 e θ_6	0	$\pm 360^\circ$

Fonte: Product specification IRB 1010.

MODELAGEM DO ROBÔ ATRAVÉS DO MATLAB® SIMSCAPE

A fim de validar as equações obtidas, modelou-se também o robô usando os softwares MATLAB® Simulink e MATLAB® Simscape, além da extensão MATLAB® Simscape Multibody. A Figura 4 retrata uma visão geral do modelo criado, no qual a estrutura do robô foi abstraída em um subsistema. O sistema recebe como entrada a posição angular de cada junta e retorna a transformada direta para cada eixo e uma que implementa a Equação (9).

Figura 4 - Visão geral do modelo do robô.




Fonte: Autoria Própria (2025).

Na Figura 5, mostra-se os seis eixos principais e o imóvel. Cada eixo é composto por duas transformadas rígidas, que são equivalentes a transformadas homogêneas, e um bloco File Solid, que permite ao usuário importar arquivos

.step de um sólido. No caso, cada File Solid foi carregado com o modelo em 3 dimensões de cada eixo do robô.

Figura 5 - Subsistema principal.



Fonte: Autoria Própria (2025).

SOLUÇÃO ANALÍTICA PARA O PROBLEMA DA CINEMÁTICA INVERSA

O problema da cinemática inversa busca encontrar os valores dos ângulos de cada junta de um robô, de modo que seu manipulador (ou ferramenta) atinja uma posição e orientação previamente definidas no espaço. Na matriz descrita pela Equação (10), os elementos r_{ij} representam a orientação e os p_x , p_y e p_z a posição do SR 6 em relação ao eixo fixo.

$${}^0M = \begin{bmatrix} r_{11} & r_{12} & r_{13} & p_x \\ r_{21} & r_{22} & r_{23} & p_y \\ r_{31} & r_{32} & r_{33} & p_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (10)$$

Assim, busca-se os ângulos θ_1 a θ_6 que tornam a Equação (11) verdadeira.

$${}^0M = {}^0T {}^1T {}^2T {}^3T {}^4T {}^5T {}^6T \quad (11)$$

Dividiu-se o problema em duas partes: primeiramente encontram-se as soluções para θ_1 , θ_2 e θ_3 e, então, as para θ_4 , θ_5 e θ_6 .

Determinação dos ângulos de junta para os três primeiros eixos

Como descrito anteriormente, as juntas 2 e 3 são responsáveis pelo posicionamento do efetuador final no espaço. Portanto, as juntas 4-6 podem ser ignoradas, conforme Figura 3. Além disso, percebe-se que a posição final está a d_4 unidades na direção y de 2_3T . Assim, tem-se que:

$${}^0T {}^1T {}^2T {}^3T \begin{bmatrix} 0 \\ d_4 \\ 0 \\ 1 \end{bmatrix} = \begin{bmatrix} p_x \\ p_y \\ p_z \\ 0 \end{bmatrix} \quad (12)$$

Multiplicou-se os dois lados da Equação (12) por 1_0T à esquerda,

$${}^1_2T {}^2_3T \begin{bmatrix} 0 \\ d_4 \\ 0 \\ 1 \end{bmatrix} = {}^1_0T \begin{bmatrix} p_x \\ p_y \\ p_z \\ 1 \end{bmatrix} = \begin{bmatrix} d_3s_2 + d_4c_2c_3 - d_4s_2s_3 \\ 0 \\ d_3c_2 - d_4c_2s_3 - d_4c_3s_2 \\ 1 \end{bmatrix} \quad (13)$$

A partir do elemento na segunda linha, obtém-se que:

$$p_y c_1 - p_x s_1 = 0 \quad (14)$$

Portanto, isolou-se os termos dependentes de θ_1 , como demonstra a Equação (15).

$$\frac{s_1}{c_1} = \frac{p_y}{p_x} \quad (15)$$


Então, aplicou-se a função atan2 para isolar-se θ_1 , conforme Equação (16):

$$\theta_1 = \text{atan2}(p_y, p_x) \quad (16)$$

É válido destacar que para $p_x = p_y = 0$ qualquer ângulo para θ_1 atende à inversa, tornando a equação Equação (16) inutilizável. Ademais, outra solução existe com uma defasagem de 180 graus, já que $\tan(\omega) = \tan(\omega + \pi)$.

$$\theta_1' = \text{atan2}(p_y, p_x) + \pi \quad (17)$$

Figura 6 - Robô planar 2r.



Fonte: Autoria Própria (2025).

Assim, encontrado θ_1 , o problema se torna equivalente à cinemática inversa de um robô planar com duas juntas, em consonância com a Figura 6.

De acordo com a Figura 6, os ângulos α , γ e θ_2 são complementares, como demonstrado na Equação (18).

$$\alpha + \gamma + \theta_2 = \frac{\pi}{2} \quad (18)$$

Isolou-se θ_2 , como exposto na Equação (19).

$$\theta_2 = \frac{\pi}{2} - (\alpha + \gamma) \quad (19)$$

Assim, a determinação de α e γ torna-se imperativa. A análise da Figura permite a obtenção de γ , como descrito pela Equação (20).

$$\gamma = \text{atan2}\left(p_z - d_1, \sqrt{p_x^2 + p_y^2}\right) \quad (20)$$

Já α pode ser encontrado pela lei dos cossenos, de acordo com a Equação (21).

$$d_4^2 = d_3^2 + (p_x^2 + p_y^2) + (p_z - d_1)^2 - 2d_3\sqrt{p_x^2 + p_y^2 + (p_z - d_1)^2} \cos(\alpha) \quad (21)$$

Como $d_4 = d_a$ isolou-se $\cos(\alpha)$, como apresenta a Equação (22).

$$\cos(\alpha) = \frac{\sqrt{p_x^2 + p_y^2 + (p_z - d_1)^2}}{2d_4} = k_2 \quad (22)$$

Portanto, aplicou-se novamente a função atan2 a fim de encontrar-se o ângulo α , representado na Equação (23).

$$\alpha = \text{atan2}\left(\sqrt{1 - k_2^2}, k_2\right) \quad (23)$$

Uma segunda solução é possível conforme Equação (24).

$$\theta_2 = \frac{\pi}{2} - (\alpha - \gamma) \quad (24)$$

A soma dos quadrados dos termos referentes a x , y e z da Equação (13), aplicada a θ_3 , resulta na Equação (25).

$$p_x^2 + p_y^2 + (p_z - d_1)^2 = d_3^2 + d_4^2 - 2s_3d_3d_4 \quad (25)$$

Isolou-se S_3 na Equação (25), de acordo com a Equação (26).

$$s_3 = \frac{d_3^2 + d_4^2 - p_x^2 - p_y^2 - (p_z - d_1)^2}{2d_3d_4} = k_3 \quad (26)$$

Então, θ_3 é dado pela Equação (27).

$$\theta_3 = \text{atan2} \left(k_3, \sqrt{1 - k_3^2} \right) \quad (27)$$

A Equação (28) mostra a segunda solução para essa junta.

$$\theta_3 = \text{atan2} \left(k_3, -\sqrt{1 - k_3^2} \right) \quad (28)$$

Ao optar pela segunda solução para θ_1 , é necessário que θ_2 execute uma rotação no sentido contrário (ou seja, assuma um valor negativo). Assim, tem-se que a terceira solução para θ_2 é dada pela Equação (29).

$$\theta_2'' = -\theta_2 \quad (29)$$

A quarta solução é equivalente ao valor negativo da segunda, como mostra a Equação (30).

$$\theta_2''' = -\theta_2' \quad (30)$$

A terceira solução para θ_3 é o suplemento da primeira solução, descrita pela Equação (29).

$$\theta_3'' = \pi - \theta_3 \quad (31)$$

A quarta para θ_3 é, novamente dada pelo suplemento da Segunda solução, conforme Eq. (30).

$$\theta_3''' = \pi - \theta_3' \quad (32)$$

Solução para os eixos 4, 5 e 6

As três últimas juntas do robô, devido à descrição de eixos adotada, somente influenciam na orientação do efetuador final. Seguindo a metodologia apresentada em Kucuk e Bingul (2004),

$${}^3T_5 {}^4T_6 {}^5T_6 = {}^3T_1 {}^2T_0 {}^1T_6 {}^0T_6 \quad (33)$$

Através da divisão dos elementos (1,3) e (3,3) da Equação (33), encontrou-se a Equação (32), que permite calcular θ_4 , conforme demonstrado na Equação (37).

$$k_{41}s_4 + k_{42}c_4 = 0 \quad (34)$$

O coeficiente k_{42} na Equação (32) é dado pela Equação (35).

$$k_{42} = r_{33}(c_2c_3 - s_2s_3) + r_{13}c_1(c_2s_3 + c_3s_2) + r_{23}s_1(c_2s_3 + c_3s_2) \quad (35)$$

Já o k_{41} é dado pela Equação (36).

$$k_{41} = r_{23}c_1 - r_{13}s_1 \quad (36)$$

Portanto, θ_4 é dado pela Equação (37).

$$\theta_4 = \text{atan2}(-k_{42}, k_{41}) \quad (37)$$

Assim como em casos anteriores, existe uma solução alternativa defasada em 180 graus, descrita pela Equação (38).

$$\theta_4' = \text{atan2}(k_{42}, -k_{41}) \quad (38)$$

A igualdade do elemento (2,3) nos dois lados da equação resulta na Equação (39).

$$c_5 = r_{13}c_1(c_2c_3 - s_2s_3) - r_{33}(c_2s_3 + c_3s_2) + r_{23}s_1(c_2c_3 - s_2s_3) = k_5 \quad (39)$$

Assim, a Equação (40) fornece a solução para θ_5 .

$$\theta_5 = \text{atan2}\left(-\sqrt{1 - k_5^2}, k_5\right) \quad (40)$$

Novamente, outra solução existe defasada em 180 graus. Essa solução é apresentada na Equação (41).

$$\theta_5 = \text{atan2}\left(\sqrt{1 - k_5^2}, k_5\right) \quad (41)$$

Ao realizar a divisão do elemento (2,1) pelo elemento (2,2), obtemos a Equação (42), a partir da qual é possível determinar o valor de θ_6 .

$$k_{61}s_6 - k_{62}c_6 = 0 \quad (42)$$

O coeficiente k_{61} é dado pela Equação (43).

$$k_{61} = r_{12}c_1(c_{23} - s_{23}) - r_{32}(c_2s_3 + c_3s_2) + r_{22}s_1(c_{23} - s_{23}) \quad (43)$$

O coeficiente k_{62} é dado pela Equação (44).

$$k_{62} = r_{11}c_1(c_{23} - s_{23}) - r_{31}(c_2s_3 + c_3s_2) + r_{21}s_1(c_{23} - s_{23}) \quad (44)$$

Assim, θ_6 pode ser calculado conforme expresso na Equação (45).

$$\theta_6 = \text{atan2}(-k_{62}, k_{61}) \quad (45)$$

Outra solução existe de acordo com a Equação (46).

$$\theta_6 = \text{atan2}(k_{62}, -k_{61}) \quad (46)$$

Solução completa

A Tabela 2 detalha as combinações de equações a serem utilizadas para determinar todas as soluções possíveis da cinemática inversa do robô em estudo. Contudo, a análise da tabela de restrições é indispensável para determinar quais soluções obtidas são fisicamente exequíveis pelo robô em questão.

Conforme mencionado anteriormente, o último eixo do robô não se encontra na extremidade do efetuador final. Portanto, para posicionar o atuador final em um ponto P, definido pela Equação (47), e com uma orientação R, descrita pela Equação (48), é necessário ajustar a matriz M de acordo com a Equação (49) dado que a extremidade do robô está a 45mm do último eixo ao longo de Z.

$$P = \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} \quad (47)$$

$$R = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \quad (48)$$

$$M = \begin{bmatrix} r_{11} & r_{12} & r_{13} & x - 45r_{13} \\ r_{21} & r_{22} & r_{23} & y - 45r_{23} \\ r_{31} & r_{32} & r_{33} & z - 45r_{33} \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (49)$$

Tabela 2 - Solução Completa.

S	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6
1 ^a	Eq (16)	Eq (19)	Eq (27)	Eq (37)	Eq (40)	Eq (46)
2 ^a	Eq (16)	Eq (19)	Eq (27)	Eq (38)	Eq (41)	Eq (45)
3 ^a	Eq (16)	Eq (24)	Eq (28)	Eq (37)	Eq (40)	Eq (46)
4 ^a	Eq (16)	Eq (24)	Eq (28)	Eq (38)	Eq (41)	Eq (45)
5 ^a	Eq (17)	Eq (29)	Eq (31)	Eq (37)	Eq (40)	Eq (46)
6 ^a	Eq (17)	Eq (29)	Eq (31)	Eq (38)	Eq (41)	Eq (45)
7 ^a	Eq (17)	Eq (30)	Eq (32)	Eq (37)	Eq (40)	Eq (46)
8 ^a	Eq (17)	Eq (30)	Eq (32)	Eq (38)	Eq (41)	Eq (45)

Fonte: Autoria Própria (2025).

GERAÇÃO DE TRAJETÓRIA

Para que a transformada inversa seja efetivamente utilizada para posicionar e orientar o manipulador final no espaço cartesiano, faz-se necessário que a trajetória a ser percorrida por cada junta seja definida, do ponto inicial ao final. A fim de que o movimento do robô seja suave, a posição angular das juntas é representada por um polinômio de terceiro grau em função do tempo, conforme:

$$\theta_i(t) = a_0 + a_1 t + a_2 t^2 + a_3 t^3 \quad (50)$$

Substitui-se $t = 0$ na Equação. (50) e encontra-se o coeficiente a_0 , como demonstrado na Equação (51).

$$\theta_i(0) = a_0 \quad (51)$$

A derivada da Equação (50) gera a velocidade em função do tempo, como mostra a Equação (52).

$$\theta'_{i(t)} = a_1 + 2a_2 t + 3a_3 t^2 \quad (52)$$

Uma vez que o robô se encontra em repouso tanto no ponto inicial quanto no ponto final da trajetória, assume-se que a velocidade angular de cada eixo seja nula nos dois instantes de tempo. Assim, para $t = 0$, obtém-se o coeficiente a_1 , conforme a Equação. (53).

$$\theta'_i(0) = a_1 = 0 \quad (53)$$

Para o instante de tempo final, denominado por t_f , a velocidade é dada pela Eq. (54).

$$\theta'_i(t_f) = 2a_2 t_f + 3a_3 t_f^2 = 0 \quad (54)$$

A Equação (55) exprime a posição angular para o instante de tempo final, denominado por t_f .

$$\theta_i(t_f) = \theta_i(0) + a_2 t_f^2 + a_3 t_f^3 \quad (55)$$

A Equação (54) e a Equação (55) formam um sistema, que pode ser utilizado para encontrar-se os coeficientes a_2 e a_3 . Para tanto, isolou-se a_3 na Equação (54), como mostra a Equação (56).

$$a_3 = -\frac{2}{3t_f} a_2 \quad (56)$$

Então, substitui-se a Equação (56) na Equação (55) e obteve-se o coeficiente a_3 , de acordo com a Equação (57).


$$a_2 = \frac{3}{t_f^2} [\theta_i(t_f) - \theta_i(0)] \quad (57)$$

Consequentemente, substitui-se a Equação (57) em Equação (54) a fim de determinar-se o coeficiente a_3 , expresso na Equação (58).

$$a_3 = \frac{2}{t_f^3} [\theta_i(t_f) - \theta_i(0)] \quad (58)$$

Então, as Equações (50), (53), (56), (57) e (58) foram implementadas no MATLAB® Simulink, para que possam ser utilizadas no modelo descrito anteriormente. A Figura 7 mostra como essa implementação foi feita. O sistema recebe como entrada a posição angular final e inicial e a duração do movimento.

Figura 7 - Geração de trajetória no Matlab® Simulink.



Fonte : Autoria propria (2025).

APLICAÇÃO

Para ilustrar a aplicação prática das equações e métodos desenvolvidos, esta seção apresenta um estudo de caso. Deve-se posicionar o efetuator final no ponto P descrito pela Equação (59).

$$P = \begin{bmatrix} 275,84 \\ -184,49 \\ 401,69 \end{bmatrix} \quad (59)$$

A orientação desejada é descrita pela Equação (60).

$${}^0R = \begin{bmatrix} -0,957 & -0,238 & 0,159 \\ 0,075 & -0,746 & -0,66 \\ 0,277 & -0,62 & 0,733 \end{bmatrix} \quad (60)$$

Portanto, a matriz M , conforme descrita pela Equação (49), foi calculada como mostra a Equação (61).

$$M = \begin{bmatrix} -0,957 & -0,238 & 0,159 & 268,04 \\ 0,075 & -0,746 & -0,66 & -154,75 \\ 0,277 & -0,62 & 0,733 & 368,69 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (61)$$

Então, conforme a Tabela 2 foram calculadas as soluções para os ângulos das juntas que levam o efetuador final para a posição P com orientação 0_6R , dadas na Tabela 3. Assim, escolheu-se utilizar 2ª solução disposta na Tabela. Então, cada trajetória foi gerada por subsistemas como o da Figura 7.


Tabela 3 - Ângulos para cada junta.

S	θ_1	θ_2	θ_3	θ_4	θ_5	θ_6
1ª	-30°	45°	-60°	-140°	50°	-90°
2ª	-30°	45°	-60°	40°	-50°	90°
3ª	-30°	75°	-120°	-110,77°	31,78°	127,61°
4ª	-30°	75°	120°	69,22°	-31,78°	52,39°
5ª	150°	-45°	-120°	-140°	-50°	90°
6ª	150°	-45°	-120°	40°	50°	-90°
7ª	150°	-75°	-60°	-110,77°	-31,78°	52,39°
8ª	150°	-75°	-60°	69,22°	31,78°	-127,61°


Fonte : Autoria propria (2025).

As Figuras 8 e 9 mostram o resultado gráfico da geração de trajetória para cada junta.


Figura 8 - Ângulos das três primeiras juntas (1, 2 e 3) em função do tempo.



(a) Primeira junta.




(b) Segunda junta.




(c) Terceira junta.
Fonte : Autoria propria (2025).


Figura 9 - Ângulos das três últimas juntas (4, 5 e 6) em função do tempo.



(a) Primeira junta.



(b) Segunda Junta.

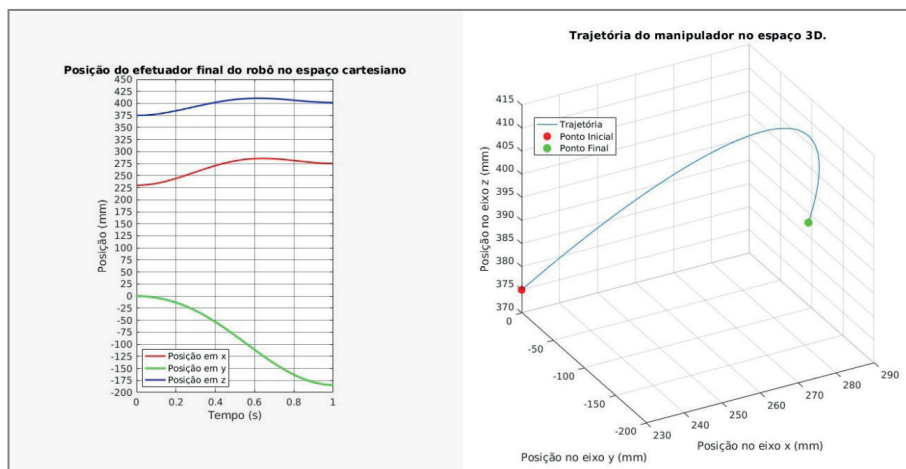


Terceira junta.

Fonte : Autoria propria (2025).

A Figura 10 (a) mostra a posição do efetuador final no espaço cartesiano. Percebe-se que o efetuador atinge a posição desejada, dada pela Equação (59). A Figura 10 (b) apresenta a trajetória do efetuador final pelo espaço cartesiano 3d.

Figura 10 - Trajetória do Robô.



Fonte : Autoria própria (2025).

CONCLUSÃO

Os resultados da simulação demonstram a validade da abordagem analítica proposta, evidenciando a correspondência entre os modelos desenvolvidos e o comportamento do robô em ambiente virtual. O trabalho reforça a importância de integrar teoria, estudo de caso e simulação no desenvolvimento de soluções aplicadas à robótica industrial, especialmente em cenários que demandam alta precisão no controle de movimento e confiabilidade operacional.

REFERÊNCIAS

ASIMOV, I.; I, Robot. **Gnome Press**, Estados Unidos, v. 1, n. 1, p. 1-253p, 1950.

ABREU, L. *et al.* Modelagem Cinemática, Planejamento e Geração de Trajetória para um Robô Modelo SCARA através de Aplicativo para Análise Gráfica. **Tópicos Especiais em Engenharia: inovações e avanços tecnológicos 7**, Ponta Grossa, PR, v. 7, n. 1, p. 43–58, lon./min. 2023.

CRAIG, J. J. Robótica. **Pearson Education do Brasil**, São Paulo, SP, v 1, ed. 3, p. 1–395, lon./min 2012.

REZENDE, L. G.; ROSSINI, F. L. Simulação da Cinemática Inversa de um Robô SCARA através da Implementação de Algoritmos por Métodos Numéricos. **Anais do XIII Seminário de Extensão e Inovação & XXVIII Seminário de Iniciação Científica e Tecnológica da UTFPR**, Ponta Grossa, PR, v. 28, n. 1, lon./min. 2023.

REZENDE, L. G.; ROSSINI, F. L. Comparação de Algoritmos por Métodos Numéricos para Obtenção da Cinemática Inversa de Robô Manipulador SCARA. **Engenharia: a máquina que constrói o futuro**, Piracanjuba, GO, v. 9, ed. 1, p. 48–64, lon./min. 2024.

ABREU, L. *et al.* Modelagem Cinemática, Planejamento e Geração de Trajetória para um Robô Modelo SCARA através de Aplicativo para Análise Gráfica. **Tópicos Especiais em Engenharia: inovações e avanços tecnológicos 7**, Ponta Grossa, PR, v. 7, n. 1, p. 43–58, lon./min. 2023.

FUDOLI, F. *et al.* Modelagem da Cinemática Direta e Inversa do Robô SCARA EPSON G10-851S. **Anais do III Simpósio de Tecnologia e Engenharia Eletrônica**, Campo Mourão, PR, lon./min. 2016.

PENHA, B. S. *et al.* Modelagem e Análise da Cinemática Direta e Inversa de Manipulador Robótico com Cinco Juntas Rotativas. **Anais do III Simpósio de Tecnologia e Engenharia Eletrônica**, Campo Mourão, PR, lon./min. 2016.

SOUZA, E. D. *et al.* Desenvolvimento de um Aplicativo no Ambiente App Designer do Software Matlab® para Planejamento de Trajetória do Robô Puma 560. **Engenharia elétrica e de computação: docência, pesquisa e inovação tecnológica**, Ponta Grossa, PR, p. 87-109, lon./min. 2023.

PONTIM, F. M. *et al.* Modelagem da Cinemática Direta de Robô com Quatro Graus de Liberdade e Simulação no Software MATLAB® via Robotics Toolbox. **Cidades inteligentes e práticas sustentáveis**, Ponta Grossa, PR, v. 2, p. 65-78, lon./min. 2025.

TAKANO, G. V. B.; ROSSINI, F. L. Modelagem e Simulação do Controle Não Linear e Variante no Tempo Aplicado à Dinâmica do Multifuncional T3-401S SYNTHIS Robô SCARA, Fabricante EPSON. **Engenharia: soluções e inovações para o desenvolvimento**, Piracanjuba, GO, v. 11, p. 79-97, lon./min. 2024.

ROSSINI, F. L. *et al.* Modelagem Dinâmica e Simulação do Sistema de Controle Não Linear do Robô Manipulador SCARA RH-3FRHR35 com Fixação Superior, Fabricante Mitsubishi. **Engenharia: a máquina que constrói o futuro**, Piracanjuba, GO, v. 17, p. 173-194, lon./min. 2023.

BARROZO, Y. R.; ROSSINI, F. L. Modelagem Matemática e Lei de Controle para o Robô Manipulador Puma 560. **Anais do XIII Seminário de Extensão e Inovação & XXVIII Seminário de Iniciação Científica e Tecnológica da UTFPR**, Ponta Grossa, PR, v. 28, lon./min. 2023.

ROSSINI, F. L. *et al.* Modeling, Simulation, Motion Trajectory Planning and Nonlinear Control in the Joint Space of the Manipulator Robot SCARA T3 401SS Manufacturer Epson. **Seven Editora**, [S.l.], lon./min. 2023.

ROSSINI, F. L. *et al.* Modelagem, Simulação e Controle de Trajetória do Robô Manipulador SCARA SR-6 IA através de um Aplicativo Matlab®. **Ciências exatas estudos e desafios**, São José dos Pinhais, PR, p. 248-278, lon./min. 2022.

LIMA, B. S. *et al.* Modelagem, Simulação e Análise de Movimento do Robô Manipulador SCARA T3 401SS Fabricante EPSON. **Engenharia Elétrica: Sistemas de energia elétrica e telecomunicações**, Ponta Grossa, PR, p. 108-125, lon./min. 2022.

ROSSINI, F. L. *et al.* Modelagem, Simulação, Planejamento de Trajetória e Controle Não Linear no Espaço de Juntas de Movimento do Robô Manipulador SCARA T3 401SS - Epson. **Engenharia: a máquina que constrói o futuro**, Piracanjuba, GO, v. 13, p. 21-41, lon./min. 2023.

SANCHES, H. E.; ROSSINI, F. L.. Modelagem e Controlador um Manipulador Robótico. **Journal of Exact Sciences** - JES,[s.l.], v. 9, n. 1, p. 5-13, 8 abr. 2016.

LYNCH, K. M.; PARK, F. C. Modern Robotics: mechanics, planning, and control. Cambridge University Press, [S.l.], v. 1, n. 3, p. 1-544, lon./min. 2017.

KUCUK, S.; BINGUL, Z. The inverse kinematics solutions of industrial robot manipulators. **Proceedings of the IEEE International Conference on Mechatronics**, [S.l.], p. 274-279, lon./min. 2004.

DESENVOLVIMENTO DE SISTEMA EMBARCADO COM REDE NEURAL PARA DETECÇÃO DE SUJEIRA EM PAINÉIS SOLARES

Rodrigo Afonso de Souza
Instituto Federal do Rio de Janeiro (IFRJ)

Gilmar Gonçalves de Oliveira
Instituto Federal do Rio de Janeiro (IFRJ)

RESUMO

Objetivo: Desenvolver um sistema embarcado de monitoramento e classificação de sujeira em painéis solares utilizando câmeras conectadas a um *Raspberry pi*, com uma rede neural convolucional treinada e uma interface para visualização dos dados. **Métodos:** Foi implementada uma rede neural convolucional (CNN) treinada com imagens térmicas, comuns e combinadas capturadas a partir de câmeras MLX90640 e OV5647, capazes de capturar distintos níveis de sujeira sobre a superfície dos painéis. As imagens foram processadas em um *Raspberry Pi* que exibe em tempo real e processa e classifica de acordo com as classes pré-definidas e usadas no treinamento, ainda com exibição de variáveis com tensão e corrente aferidos do painel com sensores INA219 e DHT11 e transmitidos via MQTT. **Resultados:** O Sistema demonstrou dificuldade em diferenciar entre as categorias treinadas, porém duas categorias se destacaram com precisão de 78% se mostrando como uma alternativa para o monitoramento da eficiência dos sistemas fotovoltaicos. A interface permite a visualização clara dos dados relevantes para decisões operacionais. **Conclusão:** A integração em *hardware* de baixo custo e visão computacional mostrou-se uma opção viável para detecção de folhas e pessoas, possibilitando intervenções pontuais, redução de perdas por sombreamento e otimização de manutenção em sistemas solares.

Palavras-chave: Câmera térmica; eficiência energética; energia solar; inteligência artificial; rede neural.

INTRODUÇÃO

A crescente busca por fontes de energia limpa e renovável tem impulsionado o desenvolvimento e a implementação de tecnologias sustentáveis ao redor do mundo. Entre elas, os sistemas fotovoltaicos se destacam por sua capacidade de transformar a luz solar diretamente em eletricidade, oferecendo uma alternativa viável às matrizes energéticas tradicionais, predominantemente baseadas em combustíveis fósseis (PORTAL SOLAR, 2023).

A energia solar fotovoltaica está firmemente estabelecida como uma das fontes renováveis mais promissoras atualmente, especialmente em países com alta incidência de radiação solar, como o Brasil (ALVES, 2020; CRESESB, 2014).

Com avanços na regulamentação, tem se observado um crescimento significativo na geração distribuída no país, incentivando a instalação de sistemas fotovoltaicos tanto em residências quanto em grandes usinas (HICKEL *et al.*, 2016).

Os painéis solares, componentes essenciais nessas instalações, normalmente são feitos de células de silício, um material semicondutor que, ao serem expostas à luz, produzem eletricidade através do efeito fotoelétrico (JACOBI *et al.*, 2021).

Essas tecnologias vêm evoluindo em eficiência, custo e escalabilidade, posicionando-se como uma peça-chave na transição energética global. Apesar de todo o potencial, os sistemas fotovoltaicos ainda enfrentam desafios, principalmente devido à exposição constante às condições ambientais.

Um dos principais problemas que prejudicam sua eficiência é o acúmulo de sujeira nas superfícies dos módulos, incluindo poeira, folhas, excrementos de aves e poluição do ar (CANAL SOLAR, 2023; CARVALHO; TOLEDO, 2022).

Essa camada de sujeira impede a passagem da luz, reduzindo a captação de radiação e, conseqüentemente, a geração de energia. Estudos mostram que a sujeira pode causar uma perda média de até 19,5% na eficiência dos módulos, podendo ultrapassar 25% em regiões secas ou com pouca chuva (KIMBER *et al.*, 2006; GOSTEIN *et al.*, 2014; ADMIN, 2019). Além da redução no desempenho, a sujeira acumulada também favorece a formação de pontos quentes, que podem danificar as células, levando a falhas precoces (CRESESB, 2014).

A limpeza regular dos painéis é essencial para garantir o bom funcionamento, mas fazer isso manualmente nem sempre é viável devido ao alto

custo, à necessidade de mão de obra especializada e à dificuldade de acesso em locais remotos (SOUZA; PEREIRA, 2022). Por isso, há uma demanda crescente por soluções automatizadas e inteligentes, capazes de monitorar e otimizar a manutenção.

A inteligência artificial (IA) aparece como uma ferramenta promissora nesse cenário. Através da análise de imagens captadas por sensores e câmeras, a IA consegue detectar padrões e identificar anomalias relacionadas à sujeira nos painéis (ALMEIDA *et al.*, 2021).

O uso de câmeras infravermelhas para análise termográfica, aliado a técnicas de visão computacional e aprendizado profundo, tem se mostrado eficaz na identificação de áreas comprometidas, mesmo em condições adversas de visibilidade (FERREIRA; COSTA, 2022; PB_COENC, 2017; EDEPE, 2020).

As redes neurais convolucionais (CNNs), que são amplamente utilizadas em visão computacional, têm demonstrado grande eficiência na segmentação e classificação de imagens, quando treinadas com dados representativos. Essas redes conseguem identificar diferentes tipos de sujeira com alta precisão, possibilitando automatizar o monitoramento dessas condições (LECUN; BENGIO; HINTON, 2015; LIPTON *et al.*, 2020; GÉRON, 2019).

Além disso, ao serem integradas a tecnologias de baixo custo, como o minicomputador Raspberry Pi, é possível realizar o processamento das imagens localmente. Essa abordagem melhora a velocidade da análise em tempo real, mesmo em locais isolados, criando soluções compactas, acessíveis e com baixo consumo energético (SANTOS; SILVA, 2022).

Com isso, o presente estudo propõe desenvolver um sistema de monitoramento embarcado, que use câmeras térmicas e visuais integradas a redes neurais convolucionais, para identificar, classificar e acompanhar o acúmulo de sujeira em painéis solares. O objetivo é aumentar a eficiência energética dos sistemas fotovoltaicos, estender sua vida útil e diminuir os custos relacionados à manutenção. Entre os objetivos mais específicos estão, o Desenvolvimento e treinamento de um modelo de inteligência artificial baseado em CNNs para análise de imagens térmicas; Classificação dos principais tipos de sujeira encontrados em módulos solares; Integração do modelo a um sistema de monitoramento capaz de emitir alertas automáticos; Avaliação do impacto da sujeira na performance dos painéis.

O objetivo é unir inovação tecnológica, viabilidade econômica e responsabilidade ambiental, utilizando os recursos naturais de forma inteligente diante do crescimento global das energias renováveis.

MATERIAIS E MÉTODOS

Este trabalho foi planejado para garantir um desenvolvimento sistemático e replicável do sistema embarcado de monitoramento e classificação de sujeira em painéis solares. O processo foi dividido em etapas bem definidas, abrangendo desde a coleta de dados até a implementação e validação do modelo de inteligência artificial. Abaixo, são descritas as principais etapas da metodologia adotada:

Definição do Problema e Objetivos

Inicialmente, foi realizada uma análise do problema relacionado ao impacto da sujeira nos painéis solares fotovoltaicos, identificando os principais tipos de sujeira (folhas, poeira, sombra, presença humana) e seus efeitos na eficiência energética. Com base nessa análise, foram definidos os objetivos do projeto, incluindo:

- Desenvolver um modelo de inteligência artificial capaz de classificar diferentes tipos de sujeira;
- Criar um sistema embarcado para monitoramento em tempo real;
- Avaliar o impacto da sujeira na performance dos painéis.

Coleta e Estruturação dos Dados

Foram capturadas imagens térmicas e visuais de superfícies fotovoltaicas utilizando sensores de baixo custo. As imagens foram categorizadas em cinco classes representativas do ambiente real: folhas, poeira, sombra, superfície limpa e interferência humana. Para ampliar a robustez do modelo, aplicou-se aumento de dados com transformações geométricas e ajustes espectrais.

Desenvolvimento e Treinamento da IA

Uma rede neural convolucional foi projetada e treinada com base em imagens de 128×128 pixels. A arquitetura foi desenvolvida utilizando as bibliotecas *TensorFlow* e *Keras* (GÉRON, 2019), com técnicas de regularização como *dropout*, *early stopping* (*parada antecipada*) e *adaptive learning rate* (*otimização adaptativa*). O treinamento foi conduzido em ambiente colaborativo com suporte a GPU, permitindo o monitoramento em tempo real das métricas de desempenho.

Integração ao Sistema Embarcado

O modelo treinado foi implantado em um *Raspberry Pi 4 Model B*, que atua como unidade central do sistema embarcado. Esse dispositivo foi escolhido por seu bom desempenho computacional, baixo consumo energético e ampla compatibilidade com sensores e periféricos. O *Raspberry Pi* é responsável por controlar sensores ambientais e realizar a inferência local do modelo de rede neural convolucional. Foram integrados sensores de temperatura e umidade (DHT11), de corrente e tensão elétrica (INA219) e duas câmeras: uma câmera térmica (MLX90640) conectada via protocolo I²C e uma câmera RGB (OV5647) conectada à interface CSI. Esses sensores capturam dados ambientais e imagens dos painéis solares em tempo real. A combinação desses dados permite compor uma visão contextual da condição dos módulos fotovoltaicos.

Interface e Comunicação

Foi desenvolvido um aplicativo Android através de plataforma visual, permitindo monitoramento remoto via protocolo MQTT. O aplicativo exibe informações em tempo real, imagens classificadas e dados ambientais, com envio automático de alertas.

Avaliação do Sistema

O desempenho do sistema foi validado com base em métricas padrões (Precisão, matriz de confusão) e em testes de campo. A integração entre os

módulos foi verificada através de execuções simuladas e reais, observando a consistência entre sensores, processamento e resposta do aplicativo.

Ferramentas e Ambientes

O sistema foi programado majoritariamente em Python, com trechos auxiliares em C++. Para o desenvolvimento do modelo de aprendizado de máquina, foram utilizadas bibliotecas como TensorFlow e Keras, que fornecem interfaces eficientes para criação e treinamento de redes neurais profundas (GÉRON, 2019). Também foram empregadas bibliotecas como *OpenCV* e *Matplotlib* para manipulação de imagens e visualização gráfica dos resultados.

Além disso, utilizou-se o *Flask*, um *microframework web* em *Python*, que possibilita a criação de interfaces *web* leves para comunicação com o sistema embarcado. O ambiente de desenvolvimento foi baseado na IDE *PyCharm*, com suporte do *Google Colab* para etapas de prototipagem e treinamento dos modelos com GPU em nuvem.


Visão Geral do Projeto

O sistema proposto foi desenvolvido para monitorar e classificar automaticamente condições com base em categorias pré-definidas de sujeira em painéis solares fotovoltaicos, utilizando uma abordagem baseada em inteligência artificial e *hardware* embarcado. A solução integra sensores, câmeras e algoritmos de aprendizado de máquina para capturar, processar e analisar dados em tempo real, garantindo um monitoramento eficiente e preciso. O Sistema é composto por três componentes principais: coleta de dados , processamento e análise, e integração com *hardware*. Para tal, foram utilizados os seguinte componentes:

- Câmeras térmica MLX90640;
- Câmera OV5647;
- ,Sensor de Corrente INA219;
- Sensor de temperatura e humidade DHT11;
- *Raspberry Pi*.

O diagrama exemplifica como funciona o sistema, o *Raspberry* é responsável pela execução dos códigos desenvolvidos em Python usando uma combinação de diversas bibliotecas. A montagem do protótipo podemos verificar na figura 1.

Figura 1 - Fluxo de Funcionamento do Protótipo – Monitor Solar.



Fonte: Própria (2025).

Placa de Desenvolvimento Raspberry Pi

Um dos principais componentes utilizados neste projeto é o *Raspberry Pi 4 Model B*, um pequeno computador de baixo custo, alto desempenho e tamanho compacto, muito usado em prototipagem, automação e aplicações embarcadas. Neste trabalho, ele foi responsável por controlar o sensor térmico MLX90640, processar as imagens capturadas, hospedar um servidor de vídeo usando Flask e interagir com a aplicação de inteligência artificial para análise de dados. (RASPERRY PI FOUNDATION, 2025).

Módulo Câmera OBV5647

A câmera OV5647 é um sensor de imagem CMOS amplamente utilizado em sistemas embarcados como o Raspberry Pi. Produzida pela *OmniVision*,

possui bom desempenho em diferentes condições de luminosidade devido à tecnologia *Backside Illumination (BSI)*, além de baixo consumo de energia e boa qualidade de imagem para aplicações de visão computacional(OmniVision, 2021).

Tabela 1 - Apresenta as especificações técnicas da câmera OV5647.

Especificação	Descrição
Sensor	CMOS
Resolução	5 megapixels (2592x1944)
Vídeo	1080p a 30 fps
Interface	MIPI(CSI)
Alimentação	5 V
Fabricante	OmniVision Technologies

Fonte: Adaptado de OmniVision (2021).

Módulo Câmera Térmica MLX90640

A MLX90640 é uma câmera térmica desenvolvida pela *Melexis*, amplamente utilizada para capturar mapas de calor e detectar variações de temperatura em sistemas embarcados. Com 32x24 pixels e sensor do tipo infravermelho (IR), ela mede temperaturas sem contato, sendo ideal para aplicações em automação, segurança e diagnóstico de falhas térmicas.

Tabela 2 - Apresenta as principais especificações técnicas da MLX90640.

Especificação	Descrição
Sensor	Infravermelho térmico (IR)
Resolução	32 × 24 pixels
Faixa de Temperatura	-40°C a +300°C
Interface	I2C
Precisão	+/- 1 ° C
Alimentação	3,3 V
Fabricante	Melexis Technologies

Fonte: Adaptado de Melexis (2025).

Sensor INA219

O INA219 é um sensor digital fabricado pela *Texas Instruments*, projetado para monitorar tensão, corrente e potência elétrica com alta precisão. Ele opera via interface I²C, facilitando a comunicação com microcontroladores como Arduino e Raspberry Pi. Seu diferencial está na capacidade de realizar medições bidirecionais com alta resolução, sendo amplamente utilizado em sistemas de monitoramento de consumo energético.(Texas Instruments, 2023).

Tabela 3 - Especificações Técnicas do Sensor INA219.

Especificação	Descrição
Taxa de Amostragem	Até 12 bits / 128 amostras por leitura
Precisão	+/-1%
Faixa de Trabalho	0 V a 26 V
Interface	I2C
Precisão	+/- 3,2 A
Tensão de Alimentação	3,3 a 5V
Fabricante	<i>Texas instruments</i>

Fonte: Adaptado de *Texas instruments* (2025).

Sensor DHT11

O DHT11 é um sensor digital amplamente utilizado para aplicações de monitoramento básico de temperatura e umidade relativa do ar. Seu custo acessível e interface simples o tornam ideal para projetos com microcontroladores, como Arduino e Raspberry Pi. Ele possui um termistor e um sensor capacitivo de umidade, integrados a um conversor analógico-digital interno, que transmite os dados em formato digital via uma única linha de dados. (Deng *et al.*, 2020).

Tabela 4 - Especificações Técnicas do Sensor DHT11.

Especificação	Descrição
Faixa de Temperatura	0°C a 50 °C
Precisão Temperatura	+/-2° C
Faixa de Umidade	20% a 90%
Interface	Digital
Precisão	+/- 5%UR
Tensão de Alimentação	3,3 a 5,5V
Frequência de Amostragem	1 Hz
Consumo	0,5 mA
Fabricante	Deng

Fonte: Adaptado de *Deng* (2025).

Módulo Solar 200 W

O painel solar utilizado neste projeto é um modelo de 200W Mono, fabricado pela Shinehui Solar Tech Co., Ltd. Ele é composto por células de silício monocristalino, conhecidas por sua alta eficiência na conversão da energia solar em eletricidade. Este painel possui uma potência nominal de 200W, com uma tensão de operação de 18V, uma tensão de circuito aberto de 21,6V e uma corrente de curto-circuito de até 10A. Além disso, conta com uma saída dupla USB de 5V e uma porta DC5521 fêmea, facilitando a alimentação direta de dispositivos de 5V. Com dimensões compactas de 280 × 280 × 3 mm, o painel é ideal para uso e instalações experimentais. (Shinehui Solar Tech Co., Ltd., 2024).

DESENVOLVIMENTO

Estratégia de Execução

O desenvolvimento do sistema embarcado para análise de eficiência em painéis solares seguiu uma abordagem modular e progressiva, permitindo testes isolados e validações parciais antes da integração final. Inicialmente, as etapas envolveram a coleta de dados ambientais e visuais, com sensores de temperatura, umidade, tensão e corrente conectados ao microcontrolador, enquanto as imagens térmicas e RGB eram captadas por câmeras acopladas ao *Raspberry Pi*.

Para garantir a consistência do banco de dados, foram desenvolvidas interfaces em Python utilizando bibliotecas como *Tkinter*, *OpenCV* e *PIL*, que permitiram a visualização e o armazenamento automático das imagens. A comunicação entre os módulos foi estabelecida por meio de conexões I2C e transmissão via MQTT, garantindo que os dados dos sensores fossem enviados com confiabilidade ao núcleo central de processamento.

Paralelamente, foram desenvolvidos scripts em *Python* para o pré-processamento e o treinamento de redes neurais convolucionais com auxílio do *TensorFlow/Keras*. Três modelos distintos foram treinados separadamente com dados provenientes de imagens térmicas, visuais e sobrepostas, permitindo comparar o desempenho entre as abordagens. Técnicas como aumento de dados (*data augmentation*), regularização com *dropout*, parada antecipada (*early stopping*) e ajuste adaptativo da taxa de aprendizado foram aplicadas para evitar o sobreajuste e aumentar a capacidade de generalização dos modelos. As categorias definidas para classificação — folhas, poeira, sombra, painel limpo e presença humana — foram baseadas em fatores críticos que impactam a eficiência da geração de energia fotovoltaica, como mostrado em pesquisas anteriores (ex: Alves, 2016).

Todas as decisões técnicas foram orientadas pelo equilíbrio entre viabilidade prática, custo e desempenho. O Raspberry Pi foi escolhido como unidade central por sua versatilidade, compatibilidade com múltiplos protocolos e sensores, suporte a linguagens como Python e C++, além de seu baixo consumo energético. Essa escolha eliminou a necessidade de computadores adicionais e viabilizou o processamento local de dados e imagens. Para o monitoramento das variáveis ambientais, os sensores foram configurados com scripts em C++, responsáveis por capturar e enviar as informações ao servidor MQTT por meio de conexões Wi-Fi. Foram utilizadas bibliotecas específicas, como *Wire.h* para I2C, *Adafruit_INA219.h* para leitura elétrica e *DHT.h* para temperatura e umidade. As informações eram então encaminhadas por meio do protocolo MQTT utilizando as bibliotecas *WiFi.h* e *PubSubClient.h*.


Para a interface web, adotou-se o microframework Flask, que permitiu construir uma aplicação leve e funcional para exibir imagens e dados em tempo real. Essa aplicação foi projetada para ser acessível a partir de qualquer dispositivo conectado à rede, mesmo por usuários com pouca ou nenhuma familiaridade

técnica. As resoluções de imagem adotadas — 128×128 e 224×224 pixels — foram definidas estrategicamente, garantindo que a qualidade da análise fosse mantida sem sobrecarregar o processamento do Raspberry Pi. A execução final do sistema foi validada em ambiente real, simulando condições de campo. O ciclo de coleta, inferência e retorno visual funcionou de maneira eficiente, demonstrando que o sistema proposto é capaz de operar de forma autônoma, robusta e com boa responsividade, atendendo tanto às necessidades técnicas quanto à acessibilidade do usuário final.

Coleta de Dados

A captura e categorização das imagens foi feita usando uma interface gráfica interativa criada com o *tkinter*, conforme mostrado na figura 1 e replicada para captura das câmeras separadamente e sobrepondo-as. Essa interface conecta-se ao stream transmitido pelo *Raspberry Pi*, permitindo que o usuário visualize os quadros em tempo real, escolha uma categoria e inicie a captura automática de imagens. A aplicação possibilita configurar um intervalo de captura (em segundos) e armazena as imagens capturadas em pastas específicas, organizadas por categoria e com *timestamps* para registrar o dia e horário em que foram coletadas.

Figura 1 - Interface de Captura de Imagens Térmicas.














Fonte: Própria (2025).

Classificação das Imagens

Para o treinamento da rede neural, foram definidas categorias de imagens: Folhas, Poeira, Sombra, PaineL Limpo e Humano. Diversas fotos foram coletadas de acordo com a tabela com as imagens da câmera térmica, da câmera normal e com as imagens das câmeras combinadas, buscando registrar o painel solar em diferentes condições. O objetivo foi reunir uma variedade de imagens para treinar uma inteligência artificial que possa, no futuro, fazer a identificação automaticamente dessas categorias.

Tabela 1 – Exemplo das Imagens Coletadas e Categorizadas.

Categoria	Exemplo	Exemplo	Exemplo
Folhas			
Poeira			
Sombra			
Painel_limpo			
Humano			

Fonte: Própria (2025).

Armazenamento das Imagens

Cada imagem capturada recebe um nome único com base em *timestamp* e é armazenada no diretório, sob uma subpasta nomeada conforme a categoria selecionada na sequência exemplificada na tabela 2, pode se verificar a quantificação dos dados coletados de cada categoria, que são distintas entre si, sendo a categoria térmica são apenas imagens do sensor mlx90640, a categoria normal são apenas imagens da camera OBV4657 e a sobreposta são imagens

do sensor e da câmera combinados via software, após a coletas essas imagens são usadas para treinamento da rede neural convolucional.

Tabela 2 - Tabela de Quantidade de Imagens Térmica / Normal e Sobreposta.

Categoria	Quant. Térmica	Quant. Normal	Quant. Sobreposta	Descrição
Folhas	368	644	470	Obstrução parcial por folhas, afetando a irradiação
Poeira	740	653	142	Acúmulo de partículas finas, diminuindo a eficiência
Sombra	428	956	186	Presença de sombras projetadas sobre o painel
Painel_limpo	201	497	403	Condição ideal de operação do painel solar
Humano	198	502	326	Deteccção de presença humana próxima ao painel

Fonte: Própria (2025).


Padronização dos Dados

Os dados passam por uma etapa de preparação antes de serem utilizados no treinamento da rede neural. O processo foi dividido em duas fases principais: a captura das imagens e sua padronização. A captura das imagens foi feita automaticamente por meio de uma interface criada em *Python*, que salvava cada imagem diretamente na pasta correspondente à sua categoria. Depois de coletar as imagens, elas passaram por um processo de padronização automatizado com um *script* em *Python*, que usando a biblioteca OpenCV.

As etapas incluíram:

- Leitura da imagem original;
- Redimensionamento para o tamanho de 128x128 pixels;
- Conversão do espaço de cores para RGB;
- Salvamento das imagens organizadas em pastas, de acordo com sua categoria.

Figura 2 - Interface de Captura de Imagens Térmicas.



Fonte: Própria (2025).


Desenvolvimento de Modelo de Rede Neural Convolucional

O modelo de rede neural convolucional (CNN, do inglês *Convolutional Neural Network*) foi implementado na linguagem *Python*, utilizando as bibliotecas *TensorFlow* e *Keras* (GÉRON, 2020). A preparação dos dados foi realizada por meio do componente *ImageDataGenerator*, que aplicou técnicas de aumento de dados (*data augmentation*), como rotação, zoom e espelhamento, com o objetivo de melhorar a capacidade de generalização do modelo e reduzir o *overfitting* — fenômeno no qual a rede aprende detalhes e ruídos específicos do conjunto de treinamento, perdendo a capacidade de generalização.

A arquitetura do modelo consistiu em múltiplas camadas convolucionais intercaladas com camadas de *pooling* (redução da dimensionalidade), seguidas de camadas densamente conectadas (*fully connected*) e finalizadas por uma camada de saída com função de ativação *softmax*, responsável por transformar os valores em probabilidades normalizadas para cada classe de saída. A rede foi compilada utilizando o otimizador *Adam*, amplamente utilizado por sua eficiência e adaptação dinâmica da taxa de aprendizado, e a função de perda *categorical crossentropy*, adequada para problemas de classificação com múltiplas categorias.

Durante o processo de treinamento, foram empregados mecanismos de monitoramento, como *EarlyStopping* (parada antecipada), que interrompe o treinamento ao detectar estagnação no desempenho, e *ReduceLROnPlateau*, que reduz automaticamente a taxa de aprendizado quando a métrica de validação não apresenta melhora, evitando oscilações e aceleração desnecessária do treinamento.

Figura 3 - Exemplificação de uma Rede Neural.



Fonte: Adaptado Exemplificação de uma Rede Neural - Acessado em 21/04/2025e Disponível em: CNN Architecture - Detailed Explanation - InterviewBit (2025).

Técnicas de Aumento de dados (Data argumentation)


Para tornar o modelo mais resistente e evitar que ele se ajuste demais aos dados de treinamento, utilizamos uma técnica chamada aumento de dados, ou data argumentation, usando a ferramenta ImageDataGenerator. Essa técnica faz várias transformações nas imagens, incluindo:

- Rotação aleatória de até 20°, o que ajuda o modelo a entender diferentes ângulos de visualização;
- Deslocamentos horizontais e verticais de até 20%, simulando variações na posição das imagens;
- Cisalhamento de cerca de 20%, que introduz pequenas distorções na geometria da imagem;
- Zoom aleatório de até 20%, ajudando o modelo a reconhecer objetos em diferentes tamanhos;
- Inversões horizontais, que simulam reflexões naturais;
- Preenchimento com o método "nearest" (mais próximo), garantindo que as bordas das imagens fiquem bem ajustadas após as transformações.

Essas transformações são configuradas no ImageDataGenerator, e juntas aumentam bastante a variedade do conjunto de dados, o que melhora

a capacidade do modelo de se adaptar às diferentes condições do mundo real conforme exemplificado na figura4.

Figura4 - Exemplo referente a *Data Argumentation*.



Fonte: Dive into Deep Learning - AstonZhang,ZacharyC.Lipton,MuLi,andAlexanderJ.Smola p590 (2021).

Divisão dos Dados em Treinamento e Validação

A base de dados foi dividida automaticamente via *script*, com 80% das imagens reservadas para o treinamento e os outros 20% para validação. Essa separação foi feita usando o parâmetro *validation_split* no *ImageDataGenerator*. Essa abordagem ajuda a garantir que o modelo seja avaliado com dados que ele ainda não viu durante o treinamento, dando uma ideia mais realista de como ele pode se sair em situações novas.

Parâmetros Gerais de Treinamento

Para o ensino das redes neurais da CNNs neste projeto, foram estabelecidos parâmetros definidos com precisão para manter o desempenho e a velocidade, levando em consideração as restrições de processamento da plataforma de execução *Raspberry Pi* e *Google Colab*.

- Tamanho do grupo escolhido foi de 32, indicando a quantidade de pontos de dados tratados antes de ajustar os parâmetros do modelo.

Este número foi selecionado, pois atinge um equilíbrio entre processamento rápido e progressão constante de treinamento, evitando o comportamento irregular e a lentidão;

- A contagem das rodadas de treinamento - passes completos através dos dados - foi definida em 100 no início, permitindo que você observe como o modelo age à medida que aprende sem passar por cima da capacidade de processamento;
- A taxa de aprendizado foi configurada inicialmente com o valor padrão do otimizador do Adam (0,001), sendo reduzido automaticamente durante o treinamento através da função *ReduceLronPlateau*, que ajusta esse valor sempre que a perda de validação estagnada. Esse sistema ajudou o modelo a melhorar sua precisão de aprendizado durante os estágios de treinamento posteriores, levando a melhores resultados de generalização e classificação.

Treinamento da rede Neural

O treinamento dos modelos foram realizados utilizando os conjuntos de dados organizados em cinco classes distintas: Folhas, Painei, Humano, Poeira e Sombra, já quantificados e apresentados anteriormente e posteriormente dividido em imagens para treinamento e imagens para validação.

Conforme a tabela 3, o treinamento foi configurado para ser realizado em 100 épocas, com parada antecipada em caso de perda de aprendizado, o treinamento começou com o modelo tendo pouco mais de 20% de precisão e foi linearmente crescendo até a maturação em entre as épocas 15 e 26, logo na etapa 27 o modelo atingiu o maior nível de precisão em validação do treinamento, vindo a seguir tendo uma redução na taxa de aprendizado e aumento da perda, sendo parado o treinamento por (*early stopping*) parâmetros pré configurados.


Tabela 3 - Evolução do Treinamento do Modelo.

Época ou etapas de treinamento	Precisão de Treino (%)	Perda de Treino	Precisão de Validação (%)	Perda Validação	Taxa de Aprendizado
1	20,42	29.363	15,96	16.023	0.0010
2	18,54	15.862	34,89	14.827	0.0010
3	37,14	13.656	46,81	11.525	0.0010
4	51,92	10.821	44,26	10.929	0.0010
5	55,51	0.9738	63,83	0.9745	0.0010
6	57,99	0.9313	63,62	0.9263	0.0010
7	60,04	0.9052	64,68	0.8870	0.0010
8	60,92	0.8391	70	0.8001	0.0010
9	65,75	0.7757	67,45	0.7768	0.0010
10	70,46	0.6760	71,06	0.6851	0.0010
11	75,3	0.6125	73,62	0.5747	0.0010
12	77,37	0.5453	75,53	0.5167	0.0010
13	77,61	0.5093	78,3	0.4772	0.0010
14	79,64	0.4971	74,89	0.5020	0.0010
15	79,02	0.4614	78,72	0.4505	0.0010
16	83,71	0.4255	76,81	0.4604	0.0010
17	80,5	0.4317	77,23	0.4344	0.0010
18	82,35	0.4113	78,3	0.4277	0.0010
19	82,42	0.4054	76,17	0.4213	0.0010
20	82,71	0.3925	77,45	0.3954	0.0010
21	84,97	0.3471	77,66	0.4087	0.0010
22	83,42	0.3789	77,23	0.4055	0.0010
23	83,63	0.3638	78,09	0.3849	0.0010
24	83,66	0.3720	77,23	0.3609	0.0010
25	84,95	0.3513	76,81	0.3844	0.0010
26	85,04	0.3641	76,81	0.3661	0.0010
27	84,94	0.3678	78,09	0.3555	0.0010
28	85,34	0.3431	75,96	0.4233	0.0010
29	85,07	0.3609	77,23	0.3929	0.0010
30	85,53	0.3356	76,81	0.3807	↓ 0.0003
31	86,16	0.3222	77,66	0.3778	0.0003
32	86,18	0.3229	75,96	0.4043	0.0003

Fonte: Própria (2025).

Como exemplificado na tabela anterior, o treinamento foi configurado para ocorrer ao longo de 100 épocas, vindo ser interrompido previamente por atingir parâmetros configuráveis, na figura 4, podemos visualizar de outra forma o progresso do treinamento do modelo.

Figura 4 - Gráfico do Resultado do treinamento IA.




Fonte: Própria (2025).

Aplicativo de Monitoramento

O aplicativo móvel foi desenvolvido utilizando a plataforma Kodular , uma ferramenta visual de programação baseada em blocos que permite criar aplicativos para Android de forma intuitiva e acessível, sem a necessidade de conhecimento avançado em linguagens de programação tradicionais. O processo de criação das telas no Kodular seguiu um fluxo estruturado, garantindo uma interface clara e funcional para o monitoramento em tempo real dos painéis solares.

Figura 9 - Aplicativo de Monitoramento da IA.




Fonte: Própria (2025).

RESULTADO

Durante o desenvolvimento do modelo de inteligência artificial para detectar sujeira em painéis solares usando uma câmera térmica, realizou-se uma análise do desempenho do sistema. Essa análise considerou métricas como assertividade e precisão, para validar o modelo treinado. Foram criados três modelos diferentes: um com imagens da câmera térmica, outro apenas com imagens da câmera normal e um terceiro que combina os dois tipos de imagens. Cada um desses modelos foi treinado usando conjuntos de dados específicos com todas as imagens, distribuídas em cinco categorias distintas. A avaliação utilizou conjuntos de teste, com aproximadamente 80% das imagens destinadas ao treinamento e os 20% restantes usados para validação, após o treinamento foram obtidos os gráficos das figuras abaixo que mostram uma evolução consistente no desempenho dos modelos conforme as épocas avançavam.

A Figura 5 mostra os valores de treino e validação para o modelo treinado com imagens térmicas.


Figura5 - Gráfico do Resultado do treinamento IA Térmica.



Fonte: Própria (2025).

Os resultados do treinamento demonstram uma evolução no desempenho do modelo ao longo das épocas. A Figura 6 apresenta os valores de treino e validação em durante épocas do treinamento da ia com as imagens das câmeras sobrepostas.


Figura 6 - Gráfico do Resultado do Treinamento Sobreposta.



Fonte: Própria (2025).

Os resultados do treinamento demonstram uma evolução no desempenho do modelo ao longo das épocas. A FIGURA 7 apresenta os valores de acurácia e perda (*loss*) para os conjuntos de treino e validação em algumas épocas selecionadas do treinamento da ia com as imagens da câmera normal.

Figura 7 - Gráfico de Treinamento do modelo de ia Normal.




Fonte: Própria (2025).

Matriz de Confusão

A matriz de confusão foi utilizada para avaliar o desempenho da CNN na classificação das imagens. Nos testes com imagens sobrepostas, o modelo obteve alta precisão para a classe "Folhas", com 39 acertos e poucos falsos positivos. A classe "Sombra" também apresentou desempenho consistente, com apenas um erro.

Por outro lado, a detecção de "Poeira" revelou maior índice de falsos negativos, indicando baixa sensibilidade nessa categoria. Algumas confusões ocorreram entre "Folhas", "Humano" e "Painel Limpo", sugerindo que características visuais similares ainda desafiavam o modelo em cenários sobrepostos.

Figura 8 - Matriz de confusão de uma Rede Neural.




Fonte: Própria (2025).

DISCUSSÃO

Este projeto teve como objetivo criar um sistema capaz de detectar diferentes entre diferentes classes de sujeira em painéis solares, usando uma câmera térmica MLX90640, uma câmera infravermelha e uma rede neural convolucional (CNN). O modelo foi treinado com imagens processadas por um Raspberry Pi e integrado a uma interface gráfica interativa. Essa interface permite capturar, categorizar e analisar as imagens em tempo real. Além disso, foram desenvolvidas interfaces específicas para cada modelo de IA treinado, facilitando a análise. Na FIGURA 9, podemos ver a interface feita em Python, que mostra as imagens das câmeras sobrepostas ao mesmo tempo, além de exibir os resultados da análise em tempo real feita pelo modelo treinado.


Figura 9 - Interface de Análise – Modelo Sobrepostas.



Fonte: AUTORIA PRÓPRIA (2025).

Na FIGURA 10, podemos ver a interface criada em *Python* que permite visualizar as imagens capturadas pela câmera, além de mostrar em tempo real os resultados da análise feita pelo modelo treinado.


Figura 10 - Interface de Análise – Modelo Câmera Normal.



Fonte: AUTORIA PRÓPRIA (2025).

Na FIGURA 11, aparece a interface em *Python* para exibir a imagem da câmera térmica, juntamente com os resultados da análise em tempo real.

Figura 11 - Interface de Análise – Modelo Térmica.



Fonte: AUTORIA PRÓPRIA (2025).

Durante a coleta das imagens, também foram medidos variáveis como tensão, corrente, temperatura e umidade, utilizando os sensores INA219 e DHT11. Para isso, foi desenvolvida uma aplicação em *Python*, usando as bibliotecas *Matplotlib* e *Adafruit*, que gera gráficos. Para projetos futuros podemos associar uma categoria ou classe com a oscilação das variáveis monitoradas, assim tornando o sistema mais redundante.

Implementar o sistema embarcado usando *Raspberry Pi* mostrou ser uma solução acessível e eficiente para fazer o monitoramento inteligente de painéis solares. Os testes indicaram que o sistema tem uma alta precisão geral, mas uma análise mais detalhada dos registros das predições feitas pela câmera revelou alguns desafios importantes. Classes como “Humano_normal” e “Painel_limpo_normal” foram identificadas com muita confiança, mostrando que o modelo está bem treinado para reconhecer esses padrões visuais. No entanto, a confiança nas predições para classes como “Sombra_normal” e “Folhas_normal” frequentemente ficou abaixo de 0,5. Isso pode acontecer por causa de imagens ambíguas, sobreposição de padrões visuais (como sombras confundidas com folhas) ou um conjunto de treinamento desequilibrado.

A análise mostrou também que o sistema está funcionando em tempo real, fazendo várias detecções por minuto e salvando automaticamente as imagens. Esse funcionamento contínuo demonstra que o sistema é forte o bastante

para operar sem parar, mas também indica a necessidade de ajustes finos para melhorar a precisão em categorias que apresentam menor confiança.

Recomenda-se equilibrar melhor o conjunto de dados, usar técnicas de aumento de dados (*data augmentation*) para classes com menos exemplos e experimentar arquiteturas mais avançadas, como *MobileNet* ou *EfficientNet*.

Além disso, a coleta simultânea de dados de sensores ambientais – como temperatura, tensão, corrente e umidade – foi fundamental para entender como essas variáveis afetam o desempenho dos painéis solares. Os gráficos gerados mostraram, por exemplo, que há uma relação negativa entre umidade e produção de energia, assim como entre poeira ou sombras e redução na tensão. Essas informações reforçam a importância de combinar monitoramento visual com sensores para manutenção preditiva. Para trabalhos futuros, é recomendado usar sensores térmicos de maior resolução, como o modelo *FLIR Lepton 3.5*, além de substituir o *Raspberry Pi* por hardware mais potente, para permitir análises mais rápidas e precisas.

CONCLUSÃO

O trabalho propôs e desenvolveu um sistema embarcado para monitoramento e classificação de sujeira em painéis solares fotovoltaicos, utilizando câmeras térmica e visível combinadas com redes neurais convolucionais (CNNs). Com base nos resultados obtidos pelas matrizes de confusão conforme exemplificado na TABELA 5, onde demonstraram o desempenho na categoria Humano, o sistema foi capaz de diferenciar das demais em 100% das vezes, porém as mesmas matrizes de confusão revelaram que o modelo enfrenta dificuldades na distinção entre classes similares, como Folhas, Painel limpo, sombra e Poeira, devido à similaridade térmica e geométricas, se confundindo entre elas. Pode-se afirmar que o sistema proposto funciona bem na detecção de presença humana próxima a painéis solares, sendo as demais classes com níveis de incerteza de até 41,30% como observado na classe folhas.

Tabela 5 - Matriz de Confusão do Modelo Normal.

Classe Verificada	Folhas	Painel Limpo	Humano	Poeira	Sombra
Folhas	42	16	0	0	3
Painel Limpo	27	172	0	0	0
Humano	0	0	188	0	0
Poeira	41	109	0	93	0
Sombra	5	13	0	1	226

Nos próximos passos, pesquisas com conjuntos de dados maiores e mais equilibrados, sensores de maior resolução e algoritmos mais avançados, como redes neurais profundas, podem ajudar a tornar o sistema ainda melhor. Essa proposta contribui para o avanço dos sistemas inteligentes de monitoramento solar e reforça o papel da inteligência artificial na busca por um futuro mais sustentável na energia.

Embora os resultados sejam satisfatórios, muitas limitações foram identificadas, como a resolução limitada da câmera térmica MLX90640, que comprometeu a precisão em detalhes finos, e o balanceamento insuficiente dos conjuntos de dados, que afetou a generalização do modelo. Para superar esses desafios, futuros trabalhos podem explorar sensores de maior resolução, câmeras com maior qualidade e *hardwares* mais potentes, para manter a qualidade das imagens, além de arquiteturas mais avançadas de redes neurais e técnicas de aumento de dados.

O artigo reforça uso da inteligência artificial e da visão computacional na solução de problemas em ambientes urbanos, rurais ou industriais.

Com a sugestões propostas, o sistema pode se tornar uma ferramenta essencial para otimizar a geração de energia renovável e apoiar a transição para um futuro mais sustentável.

REFERÊNCIAS

ALVES, Dennys Lopes. Geração solar fotovoltaica. 2. ed. São Paulo: Érica, 2020.

CANAL SOLAR. Estudo aponta perda de até 19,5% na geração por sujeira em painéis solares. Canal Solar, 2023. Disponível em: <https://canalsolar.com.br/estudo-aponta-perda-de-ate-195-na-geracao-por-sujeira-em-paineis-solares/> . Acesso em: 06 abr. 2025.

CARVALHO, Lucas. Análise do impacto da sujeira e proposta de protótipo para limpeza automatizada em sistemas fotovoltaicos. 2021. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Instituto Federal do Triângulo Mineiro, Uberaba, 2021.

CRESESB. Manual de engenharia para sistemas fotovoltaicos. Rio de Janeiro: CEPEL, 2014.

DIVE INTO DEEP LEARNING. Zhang, Aston; Lipton, Zachary C.; Li, Mu; Smola, Alexander J. Dive into deep learning. [S. l.]: d2l.ai, 2020. Disponível em: <https://d2l.ai> . Acesso em: 10 maio 2025.

EDEPE. Análise por termografia de módulos termofotovoltaicos. Revista TQM – Sustentabilidade e Energias Renováveis, edesp2_20_177_192, 2020.

GÉRON, Aurélien. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems. 2. ed. Sebastopol: O'Reilly, 2019.

GOSTEIN, F.; STONE, K.; SLAYTON, A. Quantifying soiling losses in solar photovoltaic systems. Golden: National Renewable Energy Laboratory, 2014. Acesso em: 17 julho 2025. Submission Format for IMS2004 (Title in 18-point Times font).

HICKEL, Anderson Backes *et al.* Eficiência energética e energias renováveis. Florianópolis: Eletrosul, 2016.

JACOBI, João Vitor; OLIVEIRA, Felipe Santos de; SOUSA, Ana Clara. Geração de energia solar fotovoltaica: fundamentos e aplicações. Revista Científica Multidisciplinar Núcleo do Conhecimento, v. 8, n. 1, p. 45–57, 2021. Disponível em: <https://www.nucleodoconhecimento.com.br/engenharia/energia-solar-fotovoltaica> . Acesso em: 06 abr. 2025.

KIMBER, A. *et al.* The effect of soiling on large grid-connected photovoltaic systems in California and the Southwest Region of the United States. In: IEEE 4th World Conference on Photovoltaic Energy Conference, Waikoloa, Hawaii: IEEE, 2006. p. 2391–2395.

MANUAL DE ENGENHARIA. Manual de engenharia fotovoltaica. Rio de Janeiro: CRESESB/CEPEL, 2019.

MONTENEGRO, Manuel Maria Maia Marques Líbano. Desenvolvimento de um método de detecção e análise de falhas em centrais fotovoltaicas por termografia. 2018. Dissertação (Mestrado Integrado em Engenharia da Energia e do Ambiente) – Universidade de Lisboa, Faculdade de Ciências, Departamento de Engenharia Geográfica, Geofísica e Energia, Lisboa, 2018.

PB_COENC. Análise de pontos quentes utilizando sensores à fibra óptica no monitoramento de painel fotovoltaico. 2017. Trabalho de Conclusão de Curso – Universidade Tecnológica Federal do Paraná, Curitiba, 2017.

PORTAL SOLAR. A sujeira nos painéis solares pode afetar o rendimento? Portal Solar, 2023. Disponível em: <https://www.portalsolar.com.br/sujeira-afeta-paineis-solares.html> . Acesso em: 06 abr. 2025.

SANTOS, Bruno Henrique dos. Sistemas fotovoltaicos on-grid e off-grid: comparação e aplicações. Revista Brasileira de Energias Renováveis, v. 12, n. 4, p. 112–122, 2023. Disponível em: <https://www.rber.org.br/on-vs-off-grid> . Acesso em: 06 abr. 2025.

SANTOS, Samuel Winckler. Detecção de sujeira e sombreamento em painéis solares com inteligência artificial utilizando aplicativos móveis. 2023. Trabalho de Conclusão de Curso (Engenharia de Controle e Automação) – Universidade Federal de Santa Maria, Santa Maria, RS, 2023.

SOUZA, Rodrigo M.; PEREIRA, Larissa T. Análise do impacto da sujeira na eficiência de painéis solares em regiões urbanas. *In: Congresso Nacional de Engenharia Elétrica – CONEE, 2022, Salvador. Anais [...]*. Salvador: CONEE, 2022. p. 237–245.

TOLEDO, Mateus; CARVALHO, Lucas. Sistema de monitoramento e predição de sujeira em painéis solares. 2022. Trabalho de Conclusão de Curso – Instituto Federal do Triângulo Mineiro, Uberaba, 2022.

UNICAMP – Universidade Estadual de Campinas. Efeitos da sujeira na eficiência de painéis solares: estudo do Laboratório de Energia Solar. Campinas, 2023. Disponível em: <https://www.unicamp.br/noticias/sujeira-em-paineis-solares> . Acesso em: 06 abr. 2025.

RAMOS, C. A. Figueiredo; ALCAÇO, Adérito N.; CARDOSO, A. J. Marques. Análise por termografia de módulos termofotovoltaicos. *TMQ – Techniques, Methodologies and Quality* , [S.l.], n. Ed. Especial – Sustentabilidade e Energias Renováveis, 2020.

RODRIGO Afonso de Souza; GONÇALVES de Oliveira, Gilmar. Repositório de Dados e Códigos para Desenvolvimento de Rede Neural para Detecção de Sujeira em Painéis Solares. Disponível em: https://drive.google.com/drive/folders/1-1slZ054S7xNMOUsZ7SgygeulM0CeLxV?usp=drive_link . Acesso em: 22 jun. 2025.

ZHANG, Hang *et al.* Deep learning-based photovoltaic module defect detection using thermographic images. *Renewable Energy* , v. 182, p. 527–537, 2022. DOI: 10.1016/j.renene.2022.04.061 . Disponível em: ScienceDirect . Acesso em: 22 jun. 2025.

ZORRILLA-CASANOVA, R. *et al.* Analysis of dust losses in photovoltaic modules. *Journal of Renewable and Sustainable Energy*, v. 5, n. 4, 2013. Acesso em: 17 jul. 2025. https://www.researchgate.net/publication/259811727_Analysis_of_Dust_Losses_in_Photovoltaic_Modules

INTEGRAÇÃO MECATRÔNICA ENTRE SCANNERS E EIXOS LINEARES PARA PROCESSAMENTO A LASER

Claudio Abilio da Silveira

Instituto Federal de Santa Catarina (UFSC)

Milton Pereira

Instituto Federal de Santa Catarina (UFSC)

Walter Lindolfo Weingaertner

Instituto Federal de Santa Catarina (UFSC)

RESUMO

O processamento de materiais com laser depende não somente de características ópticas, mas também dos dispositivos que propiciam a sua entrega adequada. A movimentação relativa entre o feixe laser e o ponto de processamento pode contar com diferentes sistemas de movimentação para ser executada. Nos scanners, a movimentação dos espelhos permite o direcionamento em velocidades elevadas, mas devido às suas características inerentes, o alcance do feixe sobre um plano não ultrapassa geralmente algumas centenas de milímetros. Outros sistemas de movimentação, como eixos lineares, permitem a movimentação e orientação do feixe com amplo alcance, contudo, podem apresentar velocidade e exatidão que limitam a potencialidade do uso do laser. No entanto, estes dois dispositivos podem ser combinados para usufruir de vantagens particulares, como a movimentação em altas velocidades (propiciadas pelo scanner) estendida a uma grande área de alcance (definida pelos eixos lineares). Este artigo apresenta as características encontradas em sistemas com movimentação síncrona entre scanner e eixos lineares aplicados no processamento de materiais com laser. São abordados aspectos como a velocidade, exatidão e limitações. As estratégias de utilização de scanners e características do feixe laser como potência, densidade e distribuição de energia também são citadas. Incluem-se ainda as particularidades na utilização com lasers de emissão contínua e pulsada. Conclui-se que a movimentação combinada de scanner e outros sistemas de movimentação maximiza e expande a utilização de laser no processamento de materiais, no entanto, apresenta forte dependência da integração mecatrônica entre os componentes.

Palavras-chave: Cabeçote Galvanométrico; Microusinagem a Laser; Galvo; Gravação a Laser; *on-the-fly*.

INTRODUÇÃO

O processamento de materiais com laser se estende a uma ampla gama de aplicações, como corte, microusinagem, marcação, texturização, tratamento térmico e outros. Esse processamento compreende a utilização de uma emissão de luz laser gerada por uma fonte e sua condução até a área a ser processada. Diferentes dispositivos podem ser empregados para transportar e condicionar as características do feixe laser em função do tipo de fonte utilizada e do tipo de processamento desejado. O direcionamento do feixe laser da fonte até a área de trabalho pode ser realizado por meio de elementos ópticos tais como espelhos, lentes e fibras ópticas.

A movimentação relativa do feixe laser que chega ao efetuator final em relação ao material processado pode ser realizada por uma unidade de movimentação linear, braços robóticos e, em casos específicos, por movimentação manual. A utilização de eixos lineares é amplamente difundida nos equipamentos industriais, sendo frequentemente encontrada em diversas áreas de atuação.


No entanto, a utilização de laser muitas vezes está associada à busca por velocidades de processamento mais elevadas que aquelas encontradas em sistema de movimentação convencionais. Uma forma de atender a demanda por dinâmicas elevadas para alguns processamentos com laser é o emprego de scanners (também referenciados como cabeçotes galvanométricos ou simplesmente galvos). Nestes dispositivos, o direcionamento do feixe laser ocorre por meio da sua reflexão por espelhos, o que resulta em um deslocamento rápido do ponto de incidência do laser na superfície de trabalho.

A combinação das vantagens oferecidas pelos eixos lineares, principalmente no que diz respeito à grande área de trabalho que pode ser alcançada, com a dinâmica oferecida pelos scanners galvanométricos resulta em soluções interessantes para o processamento de materiais com laser. Essa integração mecatrônica entre scanners e outros sistemas de movimentação também recebe a denominação de *"on-the-fly"* em algumas literaturas, termo usado para processos de marcação, gravação ou soldagem a laser quando realizados enquanto o objeto ou peça de trabalho está em movimento (IPG, 2024; TRUMPF, 2025).

EIXOS LINEARES

O deslocamento linear encontrado em máquinas automatizadas é comumente obtido a partir de um conjunto de guias de elementos rolantes e fuso de esferas devido à performance e modularidade propiciada por estes dispositivos (Altintas *et al.*, 2011). Devido ao baixo atrito entre os elementos das guias lineares de rolamento, observa-se uma maior resistência ao desgaste e baixa incidência do fenômeno *stick-slip* em comparação com guias de deslizamento. Um fuso de esferas recirculantes pode ser simplificaradamente descrito como um parafuso que transmite movimento para uma porca sendo que entre eles há elementos rolantes que circularam por um caminho fechado.

Nos eixos lineares voltados para aplicações que necessitem velocidades e acelerações elevadas são empregados motores lineares. Nessa abordagem, a movimentação entre as partes estáticas e móveis é gerada diretamente por uma força magnética presente na parte secundária e primária do motor (Altintas *et al.*, 2011). Embora mantenha-se o uso das guias lineares, são eliminados o acoplamento, o fuso de esferas e seus mancais. Consequentemente, a incerteza de posicionamento originada por esses elementos também é eliminada (Moriwaki, 2008). Um exemplo de configuração com motor linear e com fuso de esferas pode ser observado na Figura 1.



Fonte: adaptado de Altintas *et al.* (2011).


SCANNERS GALVANOMÉTRICOS

Os scanners galvanométricos são constituídos por elementos eletromecânicos que defletem o feixe laser utilizando espelhos com movimentos rotativos controlados. A deflexão do feixe permite orientar a posição de incidência do laser sobre uma superfície ou plano de trabalho, permitindo assim o processamento

de material. A constituição básica de um scanner galvanométrico inclui os elementos: motores, espelhos, lentes, estrutura mecânica e unidades adicionais de condicionamento do feixe laser.

O princípio de funcionamento é baseado na utilização de dois atuadores eletromecânicos com giro limitado, conhecidos como galvanômetros. Nos galvanômetros, uma corrente elétrica é inserida em uma bobina para formar um campo magnético que interage com o campo de um ímã permanente. A interação entre os campos promove a movimentação rotacional de um eixo. Um espelho acoplado ao eixo do atuador permite realizar a deflexão do feixe incidente em uma direção e, quando combinado com o movimento de outro espelho posicionado ortogonalmente, é possível orientar o feixe em duas direções (2D). Essa arquitetura com dois espelhos, que pode ser observada na Figura 2, é a mais comum nos scanners galvanométricos.

Figura 2. Arquitetura de um scanner com dois espelhos.




Fonte: adaptado de Li (2008).

Para que ocorra a focalização do feixe laser, é utilizada uma óptica que converge a emissão de luz para um dado ponto focal. Embora a convergência do feixe possa ser obtida com uso de espelhos de curvatura côncava, o uso de lentes é mais difundido nos scanners galvanométricos encontrados comercialmente. Os dois tipos básicos de configuração para as lentes focais em scanners

se dividem e pré e pós-objetiva (Chen *et al.*, 2008). No caso dos sistemas com pré-objetiva, como o ilustrado na Figura 3 (a), o feixe laser atinge primeiramente os espelhos para em seguida ser convergido por uma lente focal antes de incidir sobre a superfície do material a ser processado. Quando o feixe laser encontra a lente de foco e posteriormente é defletido pelos espelhos tem-se a configuração de scanner pós-objetiva, como ilustrada na Figura 3 (b).

Na configuração pré-objetiva, a lente de foco é projetada para manter um tamanho de ponto constante em todo o campo de escaneamento. Essas lentes específicas são conhecidas como F-theta. Nas lentes F-theta compostas por um elemento óptico simples, o erro de distorção oriunda da utilização dos espelhos é usualmente de 2 % a 3 %. Lentes com múltiplos elementos ópticos com superfície livre apresentam uma característica melhorada com erros situados abaixo de 0,36 % para distâncias focais inferiores a 75 mm (Sintetic Optronics, 2016).

Figura 3. Configuração óptica (a) pré-objetiva e (b) pós-objetiva.




Fonte: adaptado de Chen *et al.* (2008).

Outra estratégia de melhora da uniformidade da exatidão de posicionamento de foco sobre um plano é a utilização de componentes complementares à configuração tradicional dos scanners galvanométricos. Um módulo de foco dinâmico (DFM – *Dynamic Focusing Module*) é utilizado para ajustar a posição do plano de incidência do ponto focal na área de trabalho, expandindo o campo de atuação da lente F-theta (Yang *et al.*, 2016). Nessa abordagem, é inserida uma lente de expansão do feixe laser e uma lente objetiva antes da entrada no scanner. A lente de expansão possui um deslocamento ativo no sentido do eixo óptico que irá resultar em uma variação da distância vertical do ponto onde o

foco do laser incide. Esse método de minimização de erros estáticos e dinâmicos de focagem pode ser observado na Figura 4.


Figura 4. Ilustração da operação de um sistema de foco dinâmico com lente F-theta.



Esta proposta pode ser implementada ainda pela substituição da lente F-theta por uma estrutura com uma lente focal de inclinação dinâmica, realizada por um mecanismo baseado em giroscópio. A inserção do mecanismo de inclinação permite expandir o campo de trabalho do scanner para um mesmo limite de inclinação dos espelhos, situado próximo a 20° na maioria dos galvanômetros (Yang *et al.*, 2016). O uso do sistema de foco dinâmico permite corrigir os erros de focagem do laser introduzidos pelo movimento de inclinação da lente, ao ponto que o erro de posicionamento é corrigido por equacionamento matemático.

Nas abordagens que utilizam artifícios ópticos estáticos como lentes F-theta e controles dinâmicos com o sistema de variação da distância focal, o objetivo é promover uniformidade ao longo de toda a área de trabalho. Desta forma, a distribuição de energia, tamanho de foco e sua simetria apresentam pouca variação sobre o material processado. O resultado da compensação de erro utilizando um sistema de foco dinâmico pode ser observado na Figura 5.

Figura 5. Distribuição do tamanho focal (a) sem e (b) com uso de módulo de foco dinâmico para $\frac{1}{4}$ da área do scanner.




Fonte: Yang *et al.* (2016).

Observa-se que o tamanho de foco do laser indicado na Figura 5 se mantém dentro do valor esperado de 50 μm quanto mais próximo do centro de atuação da área de trabalho (Figura 5(a)). No entanto, nas áreas periféricas a regularidade decai devido ao aumento da não linearidade inerente do sistema óptico. Quando aplicada a correção provida pelo sistema de foco dinâmico, ocorre a manutenção das características desejadas do feixe ao longo de toda a área de trabalho (Figura 5(b)).

Outra categoria particular de scanners são os poligonais, onde um elemento óptico rotativo, Figura 6 (a), geralmente um espelho de metal, com três ou mais faces reflexivas, deflete o feixe laser (Marshall and Stutz, 2011). Varreduras unidirecionais, altas taxas de varredura, grandes aberturas, grandes ângulos de varredura ou grande números de pontos marcados são suas principais características de utilização. O movimento de rotação modifica o ponto no qual o laser incide sobre o espelho, resultando em um movimento linear no plano de trabalho, como representado no esquemático da Figura 6 (b). A rotação do espelho está situada entre 4.000 rpm e 20.000 (limitada pelo uso de rolamentos) e ângulos de escaneamento entre 5 ° e 70 ° são usuais (Marshall and Stutz, 2011). As altas rotações utilizadas e ausência de inversão do movimento rotativo do espelho possibilitam que a velocidade de deslocamento do feixe de laser sobre a superfície de trabalho seja uma ordem de grandeza superior à obtida por scanners galvanométricos.

Figura 6. Imagem do (a) espelho prismático e (b) sua utilização na deflexão do feixe em um scanner poligonal com óptica pré-objetiva.



Fonte: adaptado de Marshall and Stutz (2011).

Limitações em Scanners Galvanométricos

Um aspecto limitante para a utilização de scanners é o limiar de danos dos espelhos e seus revestimentos. Devido às características de dissipação térmica do substrato e do revestimento reflexivo dos espelhos, os scanners são limitados os níveis de densidade de potência compatíveis com os elementos ópticos internos. O mecanismo de danos nestes componentes varia de acordo com o tipo de emissão laser.

Na utilização de laser com emissão contínua, os efeitos térmicos são predominantes devido à fração de energia luminosa absorvida. Mesmo com uma refletividade na ordem de 99,9 %, um revestimento submetido a uma determinada potência, mas sem condições favoráveis de dissipação, pode sofrer distorções e inclusive evaporar (Brown, 2009). Espelhos projetados para densidade de energia de até 500 W/cm^2 têm alcançado resultados satisfatórios na maioria das aplicações com laser contínuo e de pulso longos. Na utilização pulsos no regime de picossegundos (ps) e femtossegundos (fs), o limiar de danos contempla efeitos de ruptura dielétrica e avalanche de elétrons, respectivamente (Dold *et al.*, 2011).

Os elementos óticos presentes no scanner também estão sujeitos a contaminações oriundas da interação entre laser e material processado. A contaminação orgânica resultante da absorção de compostos liberados por certos materiais ao longo da exposição dos elementos óticos contribui para a redução

do limiar de danos induzido pelo laser (Favrat *et al.*, 2014). O tamanho do contaminante aderido ao elemento óptico é determinante, pois quanto maior sua dimensão, mais energia é absorvida pelo espelho após o equilíbrio térmico da partícula (Han *et al.*, 2016).

A distribuição de energia do feixe laser também apresenta influência nas características de limiar de danos dos espelhos. A densidade de energia ao longo do perfil do feixe muitas vezes desvia dos modelos gaussiano e *hat-top* (Wagner *et al.*, 2015). As distribuições de energia irregulares contribuem para efeitos negativos da distorção térmica nos elementos ópticos. Os feixes laser com distribuição irregular têm essa característica morfológica acentuada pelas distorções ópticas inerentes do scanner. Uma vez que o feixe possua uma forma assimétrica, o ponto de varredura sobre o material processado estará sujeito a mudanças de tamanho e orientação a medida que se afasta do centro da área de trabalho (Li, 2008).

Uma influência negativa no processamento de materiais que demandam elevada qualidade final é a não uniformidade da densidade de energia entregue durante os movimentos de aceleração e desaceleração do scanner nos padrões de deslocamento para preenchimento e contornos. As soluções consistem em comandar o laser com exatidão a uma velocidade de varredura constante ou modular a potência em função da velocidade (Luo *et al.*, 2017).

O sistema de controle é um fator importante para a velocidade e exatidão de resposta do scanner galvanométrico. A solução mais simples a ser empregada é a chamada “malha aberta”, na qual não existe realimentação de informação com a real posição dos espelhos. Neste caso, qualquer imperfeição ou não linearidade induz a erros resultantes da diferença existente entre a posição designada e a obtida (Kacperski *et al.*, 2015).

Nas soluções de controle que apresentação um sensor de posição adicional é possível comparar a corrente posição com o valor esperado e determinar a correção necessária para compensar o desvio de erro. Nesta abordagem de malha fechada, é possível mapear de forma mais exata a posição do eixo do galvanômetro e minimizar os erros existentes. Contudo, o sensor de posição e a eletrônica adicional elevam os custos do sistema, justificando o seu uso apenas para aplicações com elevadas demandas de qualidade e produtividade (Kacperski *et al.*, 2015).

Uma das principais desvantagens dos scanners galvanométricos é o campo de varredura limitado. Isso significa que a área que o laser pode processar é relativamente pequena. Uma área maior de processamento pode ser obtida com uso de uma lente F-theta com maior distância focal, contudo, isso resulta em menor resolução lateral de posicionamento e aumento do diâmetro do laser no ponto focal. Para processar peças grandes, é necessário usar sistemas de múltiplos scanners ou mover a peça com uso de outros sistemas de movimentação, como os eixos lineares.

INTEGRAÇÃO MECATRÔNICA ENTRE EIXOS E SCANNER

Para superar a limitação de alcance dos scanners que operam em áreas de trabalho menores é possível adicionar eixos ao sistema de processamento. Essa solução, essencialmente uma integração mecatrônica, envolve a união dos dispositivos mecânicos, a comunicação e a interligação de sinais eletroeletrônicos entre os sistemas de controle do scanner e dos eixos, além de um software específico que coordena os movimentos de ambos os sistemas.


Nas configurações mais avançadas, essa integração resulta em uma movimentação síncrona entre o scanner e os eixos lineares. Isso possibilita o processamento *"on-the-fly"* (em movimento), onde a peça é processada continuamente enquanto os eixos se deslocam, otimizando a produtividade e a qualidade em grandes superfícies.

As configurações de software e hardware em equipamentos *on-the-fly* variam conforme as características dos dispositivos que constituem o sistema. Dependendo do fabricante, o processamento necessário para a movimentação síncrona entre eixo lineares e scanner galvanométrico pode estar centralizado ou distribuído entre diferentes módulos.

A composição básica inclui o conjunto de eixos lineares, o scanner galvanométrico e um sistema de controle. As informações de posição dos eixos são transmitidas para o sistema de controle. Neste sistema, é pré-calculada a posição dos espelhos do scanner. Pode ser utilizado o chamado algoritmo de offset zero, que procura manter uma distância zero entre o centro da área do scanner e a posição do laser nesta área por meio da movimentação dos eixos lineares (Kim *et al.*, 2011).

Na configuração montada pela empresa Newport, Figura 7, é possível observar a presença de um computador com o software que se comunica com hardware de controle responsável pela geração dos sinais (bloco Controlador XPS), sendo que o protocolo de comunicação utilizado é Ethernet. Os sinais gerados pelo hardware comandam os eixos lineares X e Y (bloco denominado como Eixos Newport) e o scanner galvanométrico, que recebe energia de uma fonte elétrica externa. Um bloco lógico é responsável por interpretar o programa com a trajetória a ser executada, permite adicionar movimentos sincronizados dos eixos e do scanner galvanométrico e comandar eventos externos como o disparo do laser.

Figura 7. Configuração *on-the-fly* com eixos lineares e scanner galvanométrico oferecida pela Newport.




Fonte: adaptado de Newport (2013).

Essa configuração mostrada na Figura 7 utiliza um scanner galvanométrico com uma interface de sinais XY2-100, considerada o padrão industrial para controle destes dispositivos. Esta conexão garante a alimentação dos eixos galvanométricos e a informação analógica corresponde à posição desejada dos espelhos. Para o comando do scanner galvanométrico, o hardware gera um sinal analógico de ± 10 V proporcional ao deslocamento necessário para atingir a posição determinada no programa em execução.

Uma configuração da empresa Aerotech, que integra dois eixos de movimentação linear e um scanner galvanométrico, é ilustrada na Figura 8. Novamente observa-se a utilização de software de controle de movimento baseado em computador, denominado A3800, que neste caso se utiliza o protocolo FireWire para comunicação. As informações de controle dos eixos e do scanner compartilham o mesmo barramento de comunicação que interliga os componentes em uma rede FireWire.

Figura 8. Configuração *on-the-fly* oferecida pela Aerotech.



Fonte: próprio autor (2025).

Para estabelecer a movimentação síncrona, o controlador do scanner adquire a posição real dos espelhos utilizando a informação fornecida pelo sensor de posição de cada um dos eixos do scanner galvanométrico. A informação de posicionamento real dos eixos lineares também é obtida de cada drive. Todos esses sinais de realimentação permitem ao software estabelecer a posição na qual o ponto focal do laser se encontra e determinar o comando para emissão ou desligamento da fonte laser.

Na primeira configuração, apresentada na Figura 7, os sinais de posição são enviados para o scanner galvanométrico, cuja eletrônica inserida em seu interior realiza a movimentação dos espelhos, mas não retorna à posição atingida pelos mesmos ao controlador. Na segunda abordagem, apresentada na Figura 8, o movimento é comandado pelo controlador do scanner galvanométrico, que por sua vez obtém a posição real dos espelhos e consegue transferi-la para o software de controle. Esta diferença permite que essa configuração tenha uma sincronização mais exata entre a posição do scanner galvanométrico e dos eixos lineares.

INTEGRAÇÃO COM LASER CONTÍNUO E PULSADO


Fontes laser com emissão contínua ou pulsada exigem sistemas de controle quando utilizadas com scanners galvanométricos. Contudo, algumas particularidades podem ser destacadas. Um laser contínuo requer um controle da potência entregue e um laser pulsado demanda a sincronização do movimento com os pulsos laser ou um controle adaptativo da frequência destes pulsos (Martinov *et al.*, 2014).

Ao modular a potência do laser em função da velocidade de varredura, é possível obter uma densidade de energia constante nos momentos de aceleração e desaceleração do scanner (Luo *et al.*, 2017). Nos processos de tratamento de superfície, a movimentação do feixe laser pelo scanner é combinada com a modulação de potência do laser para alterar as condições da poça fundida gerada. As alterações são resultado da variação dos parâmetros mais relevantes, como a potência média do laser, a velocidade de varredura, a amplitude da potência modulada do laser, o comprimento de onda da modulação e o diâmetro do feixe de laser (Poprawe, 2011).

Na utilização de laser com pulsos curtos comandados pelo controle de movimento dos eixos, observa-se diferentes comportamentos conforme o nível de sincronização utilizado. Quando o laser emite um trem de pulsos no início da aceleração do eixo, a distância entre os pontos atingidos varia conforme o eixo atinge sua velocidade programada, Figura 9 (a). Uma estratégia conhecida como "*sky-writing*", segundo Jaeggi *et al.*, (2013), consiste em iniciar a emissão quando os eixos já estão em uma velocidade correta, mantendo a distância

pretendida entre os pontos, Figura 9 (b). Para garantir a exatidão de posição de diferentes segmentos de linha, é necessário sincronizar o trem de pulsos do laser com a movimentação dos eixos, Figura 9 (c).


Figura 9. Posição de início com diferentes estratégias: (a) sem sky-writing, (b) com sky-writing e (c) sincronizada.



Fonte: Jaeggi et al. (2013).

Uma das funcionalidades adotadas por Aerotech (2016) é disponibilizar um sinal de saída sincronizado com a posição atual do feixe laser. A saída de posição sincronizada (PSO – *Position Synchronized Output*) gera um sinal sincronizado com a realimentação de posição do scanner e pode ser utilizada para acionar o laser. A sincronização permite estabelecer uma frequência de repetição de pulsos de acordo com a posição e a velocidade de varredura. Caso a taxa de repetição dos pulsos seja constante, a variação de velocidade irá interferir na sobreposição da incidência do laser sobre o material processado. Esse comportamento é evidenciado na Figura 10. A máxima frequência obtida em uma saída PSO diferencial situa-se em 5 MHz, sendo que a faixa típica da taxa de repetição dos lasers pulsados de ps e fs varia de centenas de kHz a alguns MHz (Niso *et al.*, 2013), muito embora lasers com GHz sejam listados para uso no processamento de materiais (Tang *et al.*, 2014).

Figura 10. Comparação do uso de laser pulsado em scanner (a) sem e (b) com posição sincronizada.



Fonte: Aerotech (2016).

Uma característica de algumas fontes laser pulsadas é que a emissão dos pulsos é baseada em uma frequência interna (*clock*) que não pode ser modificada para atuar de forma síncrona com um comando externo. Uma maneira de trabalhar com essa condição é estabelecer uma relação entre o *clock* do laser e o comando externo. Nesta abordagem, a largura de pulso do comando externo é configurada para ter a mesma largura do *clock* do laser (Aerotech, 2013). Isto garante que o sinal de comando externo estará ativo no momento em que o laser pode ser acionado (geralmente na borda de subida ou decida do *clock*). No entanto, a tolerância do sincronismo entre os sinais pode ocasionar pulsos extras caso a largura do sinal de comando seja maior que a largura do *clock* do laser ou gerar perda de pulsos na condição inversa.

Devido às exigências de qualidade para determinados processamentos de materiais, os parâmetros do laser têm sido constantemente otimizados. Para processos de microusinagem a laser, as taxas de remoção de material são melhoradas quando a largura do pulso é reduzida para a ordem de femtossegundos (Neuenschwander *et al.*, 2012). Consequentemente, a utilização de lasers de ps e fs representa o emprego de pulsos ultracurtos e elevadas taxas de repetição (acima de MHz), que por sua vez demandam mais velocidade nos sistemas de entrega de laser.

A escalada nos valores comercialmente disponíveis de potência, taxa de repetição e duração de pulso de fontes laser gera a exigência de velocidade de escaneamento superiores às encontradas na maioria dos scanners galvanométricos. Uma forma de alcançar maiores velocidades é o uso de movimentação sincronizada de eixos lineares com scanners poligonais, possibilitando velocidade de 50 m/s para um laser com taxa de repetição de 1 MHz (De Loor, 2013). Neste caso, o scanner poligonal promove uma varredura em linha de alta velocidade e o eixo linear permite a movimentação perpendicular a esta linha, resultando em um sistema de varredura 2D.

CONCLUSÃO

O processamento de materiais com laser pode usufruir das características existentes em equipamentos com a movimentação em modo *on-the-fly*, como a elevada velocidade e aceleração conferida pelos scanners galvanométricos

e a grande área de alcance dos eixos lineares. Contudo, a qualidade do resultado final depende da exatidão de sincronismo existe entre os elementos que compõem o sistema.

A compensação dos erros de não linearidade inerente ao uso dos espelhos galvanômetros e das ópticas para condicionamento do feixe também é necessária. As limitações ópticas também estão associadas ao limiar de danos dos espelhos e seus revestimentos, o que limita os níveis de densidade de energia de laser que podem ser conduzidos pelos scanners galvanométricos.

Para a utilização de laser com emissão contínua é requerido o controle da potência entregue para obter a mesma condição de energia em pontos com variação da velocidade de varredura. No uso de laser pulsado a exigência primordial é o sincronismo da frequência de pulsos com o posicionamento dado pelo sistema *on-the-fly*. Devido à escalada de desempenho de fontes laser disponíveis comercialmente, continuará crescente a busca por maiores velocidades e acelerações para o processamento de materiais por laser.

Agradecimentos

Os autores agradecem ao Laboratório de Mecânica de Precisão (LMP - LASER), à Universidade Federal de Santa Catarina (UFSC), à Financiadora de Estudos e Projetos (FINEP) e à Fundação de Amparo à Pesquisa e Inovação do Estado de Santa Catarina (FAPESC) pelo apoio na realização deste trabalho. Capítulo representa o artigo apresentado e publicado nos anais do **IX COBEF - Congresso Brasileiro de Engenharia de Fabricação, Joinville, SC - de 26 a 29 de Julho de 2017.**

REFERÊNCIAS

Aerotech. Synchronizing Position Synchronized Output (PSO) with Mode-Locked Lasers. 2013. Disponível em: <https://www.aerotech.com/media/430780/aerotech_synchronizingpsowithmode-lockedlasers.pdf>. Acesso em: 23 de nov. de 2016.

Aerotech. Nmark GCL High-Performance Galvo Control. 2016. Disponível em: <<https://www.aerotech.com/productcatalog/drives-and-drive-racks/nmark-gcl.aspx>>. Acesso em: 22 de nov. de 2016.

Altintas, Y., Verl, a., Brecher, C., Uriarte, L. and Pritschow, G. Machine tool feed drives. **CIRP Annals - Manufacturing Technology**, CIRP, Vol. 60 No. 2, pp. 779–796. 2011.

Brown, D. Optics for scanning: Rapid scanning applications drive mirror design. LaserFocusWorld, Tulsa. 2009. Disponível em: <<http://www.laserfocusworld.com/articles/print/volume-45/issue-3/features/optics-for-scanning-rapid-scanning-applications-drive-mirror-design.html>>. Acesso em: 23 de nov. de 2016.

Chen, M.-F., Chen, Y.-P., Hsiao, W.-T., Wu, S.-Y., Hu, C.-W. and Gu, Z.-P. A scribing laser marking system using DSP controller. **Optics and Lasers in Engineering**, Vol. 46 No. 5, pp. 410–418. 2008.

Dold, C., Eberle, G., Jefimovs, K., Axtner, M., Pude, F. and Wegener, K. Analysis of Damage Thresholds of Laser Scanning Mirrors using Ultrashort Laser Pulses. **Physics Procedia**, Vol. 12, pp. 445–451. 2011.

Favrat, O., Sozet, M., Tovenca-Pécault, I., Lamaignère, L. and Néauport, J. (2014). Influence of organic contamination on laser induced damage of multilayer dielectric mirrors by subpicosecond laser pulses. Proc. SPIE 9237, **Laser Induced Damage in Optical Materials**: 2014, 923707. 2014 Disponível em: <<https://doi.org/10.1117/12.2067902>>.

Han, K., Song, R., Xu, X. and Liu, Z. Influence of the contaminant size on the thermal damage of optical mirrors used in high energy laser system. Proc. SPIE 9952, **Systems Contamination: Prediction, Control, and Performance 2016**, 99520M. 2016. Disponível em: <https://doi.org/10.1117/12.2236773>.

IPG. Processamento de materiais: Soldagem a laser em tempo real. 2024. Disponível em: <<https://www.ipgphotonics.com/br/en-us/newsroom/stories/on-the-fly-laser-welding>>. Acesso em: 29 de abr. de 2025.

Jaeggi, B., Neuenschwander, B., Meier, T., Zimmermann, M. and Hennig, G. High Precision Surface Structuring with Ultra-Short Laser Pulses and Synchronized mechanical Axes. **Physics Procedia**, Vol. 41, pp. 319–326. 2013.

Kacperski, D., Włodarczyk, M. and Grabowski, K. Custom design of galvanometric motor for large mirror. **22nd International Conference Mixed Design of Integrated Circuits Systems (MIXDES)**, pp. 618–623. 2015.

Kim, K., Yoon, K., Suh, J. and Lee, J. Laser Scanner Stage *On-the-fly* Method for ultrafast and wide Area Fabrication. **Physics Procedia**, Vol. 12, pp. 452–458. 2011.

Li, Y. Beam deflection and scanning by two-mirror and two-axis systems of different architectures: a unified approach. **Appl. Opt.**, OSA, Vol. 47 No. 32, pp. 5976–5985. 2008.

De Loor, R. Polygon scanner system for ultra short pulsed laser micro-machining applications. **Physics Procedia**, Elsevier Srl, Vol. 41, pp. 544–551. 2013.

Luo, X., Li, J. and Lucas, M. Galvanometer scanning technology for laser additive manufacturing. Proc. SPIE 10095, **Laser 3D Manufacturing IV**. 2017. Disponível em: <https://doi.org/10.1117/12.2252973>.

Marshall, G. and Stutz, G. **Handbook of Optical and Laser Scanning, Performance, and Design**. 2ª Edição, Vol. 20112767, CRC Press, pp. 247–279. 2011.

Martinov, G.M., Obuhov, A.I., Martinova, L.I. and Grigoriev, A.S. An approach to building specialized CNC systems for non-traditional processes. **Procedia CIRP**, Elsevier B.V., Vol. 14, pp. 511–516. 2014.

Moriwaki, T. Multi-functional machine tool. **CIRP Annals - Manufacturing Technology**, Vol. 57 No. 2, pp. 736–749. 2008

Neuenschwander, B., Jaeggi, B., Schmid, M., Rouffiange, V. and Martin, P.-E. Optimization of the volume ablation rate for metals at different laser pulse-durations from ps to fs. Proc. SPIE 8243, **Laser Applications in Microelectronic and Optoelectronic Manufacturing (LAMOM) XVII**, 824307. 2012. Available at: <https://doi.org/10.1117/12.908583>.

Newport. Using Newport XPS Universal Controller For Control of Galvo Scanner Head. Irvine. 2013. Disponível em: <https://www.newport.com/medias/sys_master/images/images/hba/he1/8797213491230/Motion-Tech-Note-XPSControl-of-Galvo-Scanner.pdf>. Acesso em 16 de nov. de 2016. (accessed 16 November 2016).

Niso, F. Di, Gaudiuso, C., Sibillano, T., Mezzapesa, F.P., Ancona, A. and Lugarà, P.M. Influence of the Repetition Rate and Pulse Duration on the Incubation Effect in Multiple-Shots Ultrafast Laser Ablation of Steel. **Physics Procedia**, Vol. 41, pp. 698–707. 2013

Poprawe, R. (Ed.). **Tailored Light 2: Laser Application Technology**. 1ª edição, Springer-Verlag Berlin Heidelberg, Berlin. 2011.

Sintetic Optronics. Laser Marking Heads (Laser Scanners, Optical Scanners, Scan Heads). 2016. Disponível em: <<http://www.sintecoptronics.com/markinghead.asp>>. Acesso em 24 de nov. de 2016.

Tang, D.Y., Guo, J., Song, Y.F., Li, L., Zhao, L.M. and Shen, D.Y. GHz pulse train generation in fiber lasers by cavity induced modulation instability. **Optical Fiber Technology**, Vol. 20 No. 6, pp. 610–614. 2014.

TRUMPF. Marking on the fly: Marcação sincronizada em movimento. 2025. Disponível em: <https://www.trumpf.com/pt_BR/produtos/software/software-de-programacao/trutops-mark/mark-on-the-fly/>. Acesso em: 29 de abr. de 2025.

Wagner, F.R., Melninkaitis, A., Batavičiūtė, G., Gouldieff, C., Smalakys, L., Beaudier, A. and Natoli, J.-Y. Characterization of damage precursor density from laser damage probability measurements with non-Gaussian beams. Proc. SPIE 9632, **Laser-Induced Damage in Optical Materials**, 96321O, p. 96321O. 2015.

Yang, P.-M., Lo, Y.-L. and Chang, Y.-H. Laser galvanometric scanning system for improved average power uniformity and larger scanning area. **Applied Optics**, OSA, Vol. 55 No. 19, p. 5001. 2016.

MODELAGEM E PREVISÃO DO TEMPO DE DESCARGA DE BATERIAS DE LÍTIO: UMA ANÁLISE NO CONTEXTO DA INTELIGÊNCIA ARTIFICIAL

Natan Cerqueira Amorim
Instituto Federal do Rio de Janeiro (IFRJ)

Leonardo de Carvalho Vidal
Instituto Federal do Rio de Janeiro (IFRJ)

Claudeci Fonseca Medeiros
Instituto Federal do Rio de Janeiro (IFRJ)

RESUMO

A crescente eletrificação no transporte e em dispositivos eletrônicos impulsiona a demanda por Sistemas de Gerenciamento de Baterias (BMS) sofisticados, onde a previsão precisa do tempo de descarga restante de baterias de íon-lítio é crucial para a segurança e otimização. Devido à complexidade não-linear e multifatorial do comportamento de descarga, modelos tradicionais frequentemente são insuficientes. Este trabalho explora e compara duas abordagens avançadas de Inteligência Artificial: Redes Neurais Artificiais (RNAs), especificamente a arquitetura Multi-Layer Perceptron (MLP), e Lógica Fuzzy. Para as RNAs, foi desenvolvido um modelo treinado com um vasto *dataset* do NASA Prognostics Center of Excellence (PCoE), totalizando 218.397 amostras, utilizando SOC, corrente, temperatura e tensão como *features* de entrada. O treinamento com o algoritmo Levenberg-Marquardt resultou em um baixo Erro Quadrático Médio (MSE) de 0.001038 no conjunto de teste, evidenciando alta precisão e capacidade de generalização. Paralelamente, um modelo de Lógica Fuzzy foi construído utilizando variáveis linguísticas como Corrente de Descarga Relativa (CDR) e Estado de Carga (SOC), com uma base de 25 regras “SE-ENTÃO” e inferência Mamdani, resultando em previsões realistas para diversos cenários de baterias. A análise comparativa sugere que ambas as IAs são ferramentas poderosas, com potencial para sistemas híbridos neuro-fuzzy que combinam suas melhores características para BMS futuros.

Palavras-chave: Redes neurais artificiais; Fuzzy; baterias; BMS; inteligência artificial.

INTRODUÇÃO

O Crescente Universo da Eletrificação e o Desafio da Gestão de Energia

A era contemporânea é marcada por uma transição energética e tecnológica sem precedentes, onde a eletrificação desempenha um papel central. Desde a proliferação de dispositivos eletrônicos portáteis, como *smartphones* e *laptops*, até a revolução dos veículos elétricos (VEs) e sistemas de armazenamento de energia em larga escala, as baterias de íon-lítio se consolidaram como o coração pulsante dessa transformação. Sua alta densidade de energia, longa vida útil e eficiência de ciclo as tornam a escolha preferencial para uma miríade de aplicações. No entanto, a complexidade inerente ao comportamento de descarga dessas baterias apresenta um desafio significativo para engenheiros e pesquisadores: a necessidade de prever com precisão o tempo de descarga restante, conhecido como *Run-Time* ou *Range Prediction* (Zhang & Wang, 2016, Bercibar *et al.*, 2016).

A acurácia dessa previsão não é meramente uma questão de conveniência; ela é fundamental para a segurança operacional, a otimização do desempenho do sistema e o planejamento eficaz por parte do usuário. Uma estimativa imprecisa pode ter consequências sérias: interrupções inesperadas de operação, danos permanentes à bateria devido a descargas profundas excessivas, e no contexto de veículos elétricos, a temida “ansiedade de autonomia” (*range anxiety*), que inibe a adoção em massa. O comportamento de descarga de uma bateria de íon-lítio é um fenômeno altamente dinâmico e não-linear, influenciado por uma intrincada teia de fatores como a corrente de carga/descarga, a temperatura ambiente e interna da bateria, o estado de carga (SOC – *State of Charge*) e o estado de saúde (SOH – *State of Health*).

Modelos preditivos tradicionais, que frequentemente se baseiam em circuitos equivalentes ou formulações eletroquímicas, embora fundamentais para a compreensão básica, muitas vezes lutam para capturar a totalidade dessas não-linearidades e variações em condições de operação dinâmicas e imprevisíveis (Plett, 2015). Isso motiva a incessante busca por abordagens mais sofisticadas e adaptativas. É nesse cenário que a Inteligência Artificial (IA) emerge como uma solução promissora. Técnicas como a Lógica Fuzzy e

as Redes Neurais Artificiais (RNAs) se apresentam como alternativas robustas, capazes de aprender padrões complexos diretamente a partir de grandes volumes de dados ou de incorporar conhecimento heurístico e intuitivo (Ross, 2010, Haykin, 2009).

Este artigo tem como objetivo principal não apenas detalhar o desenvolvimento de modelos de previsão do tempo de descarga de baterias de íon-lítio utilizando tanto Redes Neurais Artificiais (com foco na arquitetura *Multi-Layer Perceptron*) quanto Lógica Fuzzy, mas também aprofundar a discussão sobre a importância e as vastas aplicações de cada uma dessas vertentes da Inteligência Artificial. Uma compreensão clara do funcionamento dessas IAs na predição do comportamento complexo de baterias, contextualizando a escolha de cada detalhe metodológico e explorando, de forma aprofundada, as sinergias e as diferenças fundamentais entre os dois métodos quando aplicados ao gerenciamento de energia de baterias em veículos elétricos e outros sistemas eletrônicos críticos.

Inteligência Artificial em Foco: Lógica Fuzzy e Redes Neurais Artificiais

Antes de mergulharmos nas aplicações específicas para baterias, é fundamental contextualizar a relevância e as características intrínsecas da Lógica Fuzzy e das Redes Neurais Artificiais no panorama mais amplo da Inteligência Artificial. Ambas são ferramentas poderosas para lidar com problemas complexos, mas operam com filosofias distintas.

A Lógica Fuzzy, proposta por Lotfi A. Zadeh em 1965, revolucionou a forma como os sistemas computacionais podem lidar com a incerteza e a imprecisão. Diferentemente da lógica booleana clássica, que opera em um regime binário de “verdadeiro ou falso” (0 ou 1), a Lógica Fuzzy permite que um elemento pertença a um conjunto com um grau de pertinência que varia continuamente entre 0 e 1. Isso significa que conceitos vagos e subjetivos, como “temperatura alta”, “corrente baixa” ou “bateria quase cheia”, podem ser representados e processados matematicamente (Zadeh, 1965). A relevância da Lógica Fuzzy reside na sua capacidade de mimetizar o raciocínio humano, que frequentemente opera com informações ambíguas e inexatas. Ela preenche a lacuna entre a precisão da matemática tradicional e a imprecisão do mundo real (Mendel, 2001). Os pilares de um sistema Fuzzy incluem:

Variáveis Linguísticas: Representam características do sistema em termos qualitativos (e.g., “velocidade”, “pressão”);

Termos Linguísticos (Funções de Pertinência): São os valores associados às variáveis linguísticas (e.g., para «velocidade», os termos podem ser «lenta», “média”, “rápida”). As funções de pertinência (FMs) mapeiam valores numéricos para graus de pertinência a esses termos. Funções trapezoidais e triangulares são comumente utilizadas para isso;

Base de Conhecimento (Regras SE-ENTÃO): Constitui o conjunto de regras lógicas que conectam as entradas às saídas, geralmente na forma de “SE (condição) ENTÃO (ação)”. Essas regras codificam o conhecimento de especialistas ou a experiência sobre o comportamento do sistema;

Mecanismo de Inferência Fuzzy: Processa as entradas e as regras para determinar o grau em que cada regra é ativada. O método de inferência Mamdani é um dos mais populares;

Defuzzificação: Converte o resultado Fuzzy (um conjunto de graus de pertinência) de volta para um valor numérico “crisp” que pode ser usado para controle ou previsão. O método do Centróide (*Center of Area* - COA) é amplamente utilizado.

Aplicações da Lógica Fuzzy: A flexibilidade e interpretabilidade da Lógica Fuzzy permitiram sua aplicação em uma vasta gama de campos:

Controle Industrial: Desde máquinas de lavar e geladeiras até sistemas de controle de processos complexos, a Lógica Fuzzy otimiza o desempenho em ambientes incertos;

Eletrônicos de Consumo: Câmeras digitais com foco automático, sistemas de ar-condicionado inteligentes e sistemas de freio ABS utilizam algoritmos Fuzzy para tomadas de decisão mais eficientes;

Medicina: Diagnóstico de doenças, sistemas de suporte à decisão clínica e controle de dosagem de medicamentos;

Finanças: Previsão de mercados, gerenciamento de riscos e análise de crédito;

Robótica: Controle de movimento, navegação autônoma e interação humano-robô;

Automotivo: Sistemas de controle de tração, transmissão automática e, como veremos, gerenciamento de baterias em veículos elétricos.

Redes Neurais Artificiais (RNAs): Aprendizado a partir de Dados

As Redes Neurais Artificiais são modelos computacionais inspirados na estrutura e funcionamento do cérebro humano, especificamente na forma como os neurônios biológicos se interconectam e processam informações (Haykin, 2009). Elas são a base do aprendizado de máquina profundo (*deep learning*) e se destacam pela sua capacidade de aprender padrões complexos e relações não-lineares diretamente a partir de grandes volumes de dados, sem a necessidade de programação explícita de regras.

Importância e Conceitos Fundamentais: A importância das RNAs reside na sua habilidade de “aprender” com exemplos, generalizando esse conhecimento para dados não vistos. Isso as torna ideais para tarefas como reconhecimento de padrões, classificação e regressão (Bishop, 1995). Os elementos-chave de uma RNA incluem:

Neurônios (Nós): As unidades básicas de processamento que recebem entradas, aplicam uma função de ativação e produzem uma saída;

Pesos e Vieses: Parâmetros ajustáveis que determinam a força das conexões entre os neurônios e o limiar de ativação. O aprendizado da rede consiste no ajuste desses parâmetros.

Camadas: As redes são organizadas em camadas:

Camada de Entrada: Recebe os dados brutos;

Camadas Ocultas: Realizam a maior parte do processamento, extraindo *features* e padrões abstratos. Pode haver uma ou múltiplas camadas ocultas;

Camada de Saída: Produz o resultado final da rede;

Funções de Ativação: Introduzem a não-linearidade, permitindo que a rede aprenda relações complexas (e.g., sigmoide, ReLU, *tansig*);

Algoritmo de Treinamento: Processo iterativo onde os pesos e vieses são ajustados para minimizar uma função de perda (erro) entre a saída da rede e o *target* real. Algoritmos como o *backpropagation* e *Levenberg-Marquardt* são comumente usados;

Aplicações das Redes Neurais Artificiais: As RNAs impulsionam muitas das inovações atuais em IA:

Visão Computacional: Reconhecimento facial, detecção de objetos, carros autônomos;

Processamento de Linguagem Natural (PLN): Tradução automática, *chatbots*, análise de sentimentos, assistentes de voz;

Sistemas de Recomendação: Sugestão de produtos, filmes e músicas em plataformas digitais;

Diagnóstico Médico: Análise de imagens médicas (raio-X, ressonância) para detecção de anomalias;

Previsão: Previsão do tempo, previsão de demanda, previsão de falhas de equipamentos e, claro, previsão do tempo de descarga de baterias;

Jogos: Desenvolvimento de IA para jogos e robótica.

Gerenciamento Inteligente de Baterias de Lítio: Aplicação e Metodologia

Com o contexto das duas abordagens de IA em mente, podemos agora mergulhar nos detalhes de sua aplicação para a previsão do tempo de descarga de baterias de íon-lítio, um componente vital para sistemas de gerenciamento de baterias (BMS).

O Cenário das Baterias de Lítio e a Necessidade de Previsão Precisa

As baterias de íon-lítio são onipresentes, desde pequenos dispositivos eletrônicos até os volumosos pacotes de energia que impulsionam veículos elétricos modernos (Plett, 2015). No entanto, sua natureza eletroquímica complexa significa que o processo de descarga não é linear e é influenciado por uma série de variáveis ambientais e operacionais. Uma previsão imprecisa do tempo restante de descarga pode resultar em ineficiências operacionais, riscos de segurança e, no caso de VEs, a já mencionada “ansiedade de autonomia” (*range anxiety*).

Fatores como o Estado de Carga (SOC) e a Corrente de Descarga exercem uma influência primária no tempo de uso disponível. Contudo, a tensão da bateria e, crucialmente, sua temperatura de operação, também impactam significativamente a eficiência e a capacidade utilizável. Modelos estáticos ou baseados em ampere-hora simples (que apenas somam a corrente ao longo do tempo) são insuficientes para capturar essas dinâmicas complexas, muito menos o efeito do envelhecimento da bateria (SOH). Isso reforça a busca por modelos inteligentes, capazes de aprender e generalizar a partir de grandes volumes de dados experimentais ou de conhecimento especializado.

Abordagem com Redes Neurais Artificiais (RNAs) para Previsão de Baterias

Para a previsão de tempo de descarga de baterias, as RNAs são particularmente adequadas devido à sua capacidade inata de mapear funções não-lineares complexas, que caracterizam o comportamento eletroquímico e térmico das baterias.

Arquitetura Multi-Layer Perceptron (MLP)

A MLP é uma arquitetura *feedforward* onde as informações fluem em uma única direção. Para a tarefa de prever o tempo de descarga, o modelo MLP foi cuidadosamente configurado:

Camada de Entrada: Composta por 4 neurônios, cada um recebendo uma *feature* de entrada crítica: Estado de Carga (SOC), Corrente de

Descarga (A) , Temperatura da Bateria (°C) e Tensão da Bateria (V). A escolha dessas *features* é fundamental, pois elas representam os parâmetros mais influentes no comportamento de descarga;

Camada Oculta: Optou-se por uma única camada oculta contendo 15 neurônios. Essa decisão representa um compromisso entre a capacidade de modelar as não-linearidades esperadas e o risco de *overfitting*. Uma camada oculta única com um número moderado de neurônios pode ser surpreendentemente eficaz para muitos problemas de regressão. A função de ativação escolhida para esta camada foi a tangente sigmoide (*tansig*). Essa função, que mapeia entradas para o intervalo $[-1, 1]$, é benéfica para normalizar as ativações dos neurônios e promover a estabilidade durante o treinamento, além de introduzir a não-linearidade necessária para o aprendizado de relações complexas;

Camada de Saída: Possui 1 neurônio , pois o objetivo é prever um único valor contínuo: o tempo de descarga restante. Para problemas de regressão, a função de ativação linear (*purelin*) é a escolha padrão, permitindo que a rede produza qualquer valor real como saída, sem restrições de intervalo.

O Rigor da Preparação e Pré-processamento dos Dados para RNAs

A “qualidade” dos dados é o insumo mais crítico para o sucesso de um modelo de RNA; dados ruins levam a modelos ruins.

Coleta de Dados Robusta: Os dados experimentais de descarga de baterias de íon-lítio foram coletados de *datasets* públicos e confiáveis, especificamente do *NASA Prognostics Center of Excellence (PCoE) Data Repository*. Esses *datasets* são valiosos por conterem registros detalhados de ciclos de carga e descarga sob uma diversidade de condições operacionais (incluindo tempo, tensão, corrente e temperatura). Para este estudo, foram utilizados os *datasets* fornecidos pela NASA, totalizando impressionantes 218.397 amostras de pontos de descarga. Esta vasta quantidade de dados é crucial para que a RNA possa aprender e generalizar o complexo comportamento das baterias;

Extração de *Features* e *Target* Cuidadosa: Para cada ponto de medição em um ciclo de descarga, foram extraídas as *features* de entrada: SOC (calculado indiretamente via tensão normalizada, uma proxy eficaz na ausência de medição direta), Corrente de Descarga, Temperatura e Tensão. O *target* (saída) para a RNA foi o Tempo de Descarga Restante em minutos, representando o tempo desde a medição atual até o fim do ciclo de descarga.

Limpeza de Dados Essencial: A presença de valores ausentes (NaN) ou infinitos (Inf) nos dados de entrada ou saída pode corromper severamente o processo de treinamento de uma RNA. Por isso, uma etapa rigorosa de pré-processamento foi implementada para identificar e remover quaisquer linhas que contivessem esses valores, garantindo a integridade e a validade dos dados para o treinamento.

Normalização (Escalonamento) para Melhor Desempenho: As Redes Neurais funcionam de forma mais eficiente quando os dados de entrada e saída são escalonados para um intervalo padrão, como [0,1] ou [-1,1]. A normalização Min-Max foi empregada, não apenas para evitar que *features* com magnitudes numéricas maiores dominassem o processo de aprendizado, mas também para acelerar a convergência do treinamento. A seguinte fórmula aplicada para garantir que todos os dados estivessem na mesma escala:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Divisão Estratégica do *Dataset*: Para garantir uma avaliação robusta e imparcial do modelo, o conjunto de dados total (218.397 amostras) foi dividido aleatoriamente em três subconjuntos:

Conjunto de Treinamento (70% - 152.878 amostras): Usado para ajustar os pesos e vieses da rede;

Conjunto de Validação (15% - 32.759 amostras): Monitora o desempenho da rede durante o treinamento, auxiliando na detecção e prevenção de *overfitting*, ou seja, quando a rede aprende demais os

dados de treinamento e falha em generalizar para novos dados;

Conjunto de Teste (15% - 32.760 amostras): Utilizado para avaliar o desempenho final da rede em dados completamente novos e não vistos durante o treinamento, fornecendo uma estimativa imparcial de sua capacidade de generalização.

O Processo de Treinamento e Avaliação da Rede Neural

O treinamento de uma RNA é um processo iterativo e refinado, visando minimizar o erro entre as previsões da rede e os valores reais.

Algoritmo de Treinamento Levenberg-Marquardt: O algoritmo *Levenberg-Marquardt* (*trainlm*) foi escolhido por sua reputação de velocidade e eficiência para problemas de regressão em redes de tamanho moderado. Ele combina a robustez do método de gradiente descendente com a rapidez de convergência do método de Gauss-Newton, sendo particularmente eficaz em encontrar mínimos para funções de erro não-lineares;

Função de Perda MSE: O Erro Quadrático Médio (MSE - *Mean Squared Error*) foi a função de perda central. O MSE quantifica a média dos quadrados das diferenças entre os valores previstos e os valores reais, fornecendo uma métrica da magnitude do erro da rede, e o objetivo principal do treinamento é minimizá-la;

Critérios de Parada Estratégicos: Para garantir a convergência adequada e, crucialmente, prevenir o *overfitting*, foram definidos critérios de parada bem estabelecidos:


Máximo de 1000 épocas (iterações completas por todo o conjunto de treinamento);

Meta de Performance (MSE atingir um valor muito baixo de $1e-5$);

Falhas de Validação (treinamento interrompido se o erro no conjunto de validação não diminuir por 6 épocas consecutivas, um forte indicativo de *overfitting*);

Gradiente Mínimo (para se o gradiente de performance for muito pequeno, $1e-6$, indicando que a rede não está mais aprendendo significativamente). A Figura 1 apresenta a interface do MATLAB utilizada no processo de treinamento da RNA.

Figura 1 - Treinamento da Rede Neural no software Matlab.




Fonte: Autoria própria (2025).

Avaliação Abrangente do Desempenho: Após o treinamento, o desempenho da RNA foi rigorosamente avaliado em todos os três conjuntos de dados (treinamento, validação e teste) para verificar sua precisão e, mais importante, sua capacidade de generalização para dados nunca antes vistos;

Métricas de Erro: Os MSEs obtidos foram impressionantemente baixos e próximos entre si: MSE (Treinamento): 0.001047; MSE (Validação): 0.001081; MSE (Teste): 0.001038. A proximidade desses valores é um forte indicativo de que a rede generalizou bem e não sofreu de *overfitting*, o que é um sinal de um modelo robusto;

Gráficos de Performance: A Figura 2 ilustra a curva de performance do treinamento (MSE vs. Épocas), mostrando a rápida diminuição do erro e a convergência das curvas para os três conjuntos de dados, o que é um sinal de um treinamento bem-sucedido.


Figura 2 - Performance do Treinamento da RNA (MSE vs. Épocas).



Fonte: Autoria própria (2025).

Exemplo de Previsão: Para tangibilizar a aplicação do modelo, uma previsão de exemplo foi realizada com as seguintes condições: SOC de 75%, Corrente de 5A, Temperatura de 25°C e Tensão de 38V. A Rede Neural previu um Tempo de Descarga Restante de 267.73 minutos. Este valor é obtido após a desnormalização da saída da rede, que opera com valores escalonados. Os gráficos de regressão evidenciam a correlação entre os valores reais e as saídas previstas pela rede, conforme ilustrado na Figura 3.

Figura 3 - Regressão da RNA (Targets Reais vs. Saídas da Rede).



Fonte: Autoria própria (2025).

Abordagem com Lógica Fuzzy para Previsão de Baterias

A Lógica Fuzzy oferece uma alternativa elegante e interpretável para modelar a previsão do tempo de descarga de baterias, especialmente quando o conhecimento heurístico sobre o sistema é abundante.

Detalhes do Modelo Fuzzy

O modelo Fuzzy foi construído para capturar a relação entre o estado de carga e a corrente de descarga, e como esses fatores influenciam o tempo remanescente da bateria.


Variáveis de Entrada e Saída (Linguísticas): Conforme apresentado anteriormente, as variáveis numéricas são convertidas em linguísticas.

Para este modelo, as entradas são a Corrente de Descarga Relativa (CDR) e o Estado de Carga (SOC). A saída é o Tempo de Descarga Estimado Relativo (TDER). As classificações linguísticas (e.g., *Muito Baixa*, *Baixa*, *Média*, *Alta*, *Muito Alta* para CDR e SOC; *Muito Curto*, *Curto*, *Médio*, *Longo*, *Muito Longo* para TDER) são cruciais para a interpretabilidade;

Fuzzificação e Funções de Pertinência: O processo de fuzzificação é o primeiro passo, onde os valores de entrada “crisp” são mapeados para graus de pertinência em múltiplos conjuntos Fuzzy através de funções de pertinência (FMs). Essas FMs, muitas vezes triangulares ou trapezoidais, são definidas para cada termo linguístico, permitindo que uma única entrada numérica contribua para vários estados Fuzzy (e.g., uma corrente pode ser “média” em um grau de 0.7 e “alta” em um grau de 0.3);


Base de Conhecimento e Regras SE-ENTÃO: A base de conhecimento é composta por um conjunto de regras “SE-ENTÃO” que encapsulam o conhecimento de especialistas ou o comportamento observado da bateria. Por exemplo, uma regra pode ser: “SE CDR é CDR_Media E SOC é SOC_Medio ENTÃO TDER é TDER_Medio”. A inclusão de 25 regras (5 para CDR × 5 para SOC) garante que todas as combinações relevantes sejam cobertas, permitindo uma resposta abrangente do sistema para diversas condições operacionais. A visualização dessas regras e sua ativação através do *Rule Viewer* (Figura 4 e Figura 5) é uma vantagem da Lógica Fuzzy, pois torna o processo decisório transparente.

Figura 4 - Fuzzy Logic Designer no software Matlab.



Fonte: Autoria própria (2025).

Figura 5 - Visualização Interativa do Rule Viewer no software Matlab.



Fonte: Autoria própria (2025).


Inferência Fuzzy Mamdani e Defuzzificação por Centroide: O método de inferência Mamdani foi escolhido para combinar os graus de pertinência das entradas com as regras Fuzzy, resultando em um conjunto Fuzzy de saída. A defuzzificação, por sua vez, converte esse conjunto Fuzzy de saída em um valor numérico "crisp" único (o TDER) que pode ser utilizado para a previsão. O método do Centroide (*Center of Area* - COA) é amplamente utilizado por seu equilíbrio entre simplicidade e eficácia.

Implementação e Simulação no MATLAB

O modelo Fuzzy foi implementado utilizando o MATLAB e a Fuzzy Logic Toolbox. O processo de construção envolveu o uso de funções como *newfis* para iniciar o sistema, *addvar* para adicionar variáveis de entrada/saída, *addmf* para definir as funções de pertinência e *addrule* para codificar as regras Fuzzy na forma de uma matriz numérica.

Análise da Superfície de Previsão: Um aspecto visualmente impactante e informativo do modelo Fuzzy é a superfície de previsão (Figura 6), obtida via *surfview(fis)*. Esta superfície 3D ilustra como o Tempo de Descarga Estimado Relativo (TDER) varia em função da Corrente de Descarga Relativa (CDR) e do Estado de Carga (SOC). A forma da superfície reflete diretamente a lógica programada nas regras, demonstrando as relações não-lineares aprendidas pelo sistema de forma transparente: pontos onde CDR é baixa e SOC é alta correspondem a TDERs altos, e vice-versa.

Figura 6 - Superfície de Previsão de Tempo de Descarga Fuzzy.



Fonte: Autoria própria (2025).

Cenários de Simulação e Resultados Práticos: Para validar a versatilidade do modelo, foram simulados diversos cenários, abrangendo desde uma célula base de lítio (associando células de íon-lítio do tipo 18650, 3,7 V e 2200 mAh cada, totalizando 8,8 Ah de capacidade nominal, até atingir a tensão nominal de 90 V) até grandes pacotes de baterias de veículos elétricos de ponta, como o Renault Kwid E-Tech , BYD Dolphin e Tesla Model 3 Long Range. A previsão do tempo de descarga real (em minutos/horas) é calculada escalonando o TDER com base na capacidade real (Ah) e na corrente de descarga observada da bateria. A fórmula para o cálculo do tempo estimado é crucial:

$$\text{Tempo Estimado (Horas)} = \frac{\text{Capacidade (Ah)} \times (\text{SOC}/100)}{\text{Corrente de Descarga Real (A)}} \times \text{TDER}$$

Onde:

Capacidade(Ah) é a capacidade nominal da bateria em Ampere-horas;

SOC é o Estado de Carga atual em porcentagem;

Correntede de Descarga Real (A) é a corrente de descarga instantânea em Ampères;

TDER é o Tempo de Descarga Estimado Relativo, a saída defuzzificada do modelo Fuzzy.

Os resultados detalhados das simulações para cada cenário são apresentados na Tabela 1.

Tabela 1 - Resultados das simulações para cada cenário.

Cenário/ Bateria	Capacidade (kWh/Ah)	Tensão (V)	Corrente de Descarga Real (A)	SOC (%)	CDR (Input Fuzzy) (%)	Tempo Nominal (horas)
(Associações 90V)	8.8 Ah	90	5	75	25	1.32
Renault Kwid E-Tech	26.8 kWh (81.2 Ah)	330	40	80	26.67	1.62
BYD Dolphin	60.4 kWh (151 Ah)	400	100	60	25.00	0.91
Tesla Model 3 LR	75 kWh (187.5 Ah)	400	200	45	36.36	0.42

Fonte: Autoria própria (2025).

Os resultados detalhados das simulações (Tabela 1) demonstraram a capacidade do modelo de fornecer previsões realistas e diferenciadas para cada cenário. Isso reflete a influência da corrente de descarga e do estado de carga no tempo remanescente da bateria, mesmo com as não-linearidades intrínsecas, e valida a flexibilidade do modelo Fuzzy.

DISCUSSÃO

O estudo demonstrou que tanto as Redes Neurais Artificiais quanto a Lógica Fuzzy são abordagens viáveis e poderosas para o complexo método para previsão do tempo de descarga de baterias de íon-lítio. A escolha entre elas deve ser estratégica, ponderando entre a necessidade de alta precisão baseada em dados empíricos massivos (RNAs) e a demanda por interpretabilidade,

flexibilidade na aplicação a diferentes sistemas e a possibilidade de incorporar conhecimento heurístico (Lógica Fuzzy).

A Lógica Fuzzy, com sua capacidade de mimetizar o raciocínio humano, oferece uma transparência que as RNAs, muitas vezes, não conseguem igualar. Isso é particularmente valioso em aplicações onde a explicação do “porquê” de uma previsão é tão importante quanto a previsão em si. A flexibilidade do modelo Fuzzy em lidar com diferentes capacidades e tipos de bateria, através de uma parametrização relativa, é uma vantagem econômica e de engenharia significativa.

As Redes Neurais, por outro lado, empurram os limites da precisão. Quando há uma abundância de dados de alta qualidade e o sistema pode aprender padrões complexos, as RNAs demonstram um desempenho superior na captura de nuances e não-linearidades que podem ser difíceis de codificar manualmente em um sistema Fuzzy. A proximidade dos resultados de MSE entre os conjuntos de treinamento, validação e teste para o modelo de RNA é uma prova robusta de sua capacidade de generalização e de sua resiliência contra o *overfitting*, um problema comum no aprendizado de máquina.

A sinergia entre as duas abordagens, através de sistemas híbridos Neuro-Fuzzy, é a fronteira mais promissora. Tal combinação pode unir a capacidade de aprendizado e generalização das RNAs com a interpretabilidade e a facilidade de integração de conhecimento da Lógica Fuzzy. Essa abordagem híbrida pode resultar em sistemas de gerenciamento de bateria que não apenas fornecem previsões altamente precisas, mas também permitem um entendimento mais profundo de como essas previsões são geradas, facilitando a depuração, a otimização e a confiança no sistema em aplicações críticas. Em um mundo cada vez mais dependente de energia portátil e eficiente, o desenvolvimento contínuo e a aplicação inteligente dessas tecnologias de IA são fundamentais para maximizar a vida útil das baterias, otimizar seu desempenho e garantir a segurança do usuário.

REFERÊNCIAS

- BEALE, M. H., Hagan, M. T., & Demuth, H. B. (2020). Neural Network Toolbox™: Design and Simulation of Artificial Neural Networks in MATLAB. MathWorks.
- BERECIBAR, M. *et al.* Critical review of state of health estimation methods of Li-ion batteries for real applications. *Renewable and Sustainable Energy Reviews*, v. 56, p. 572–587, 2016.
- BISHOP, C. M. *Neural Networks for Pattern Recognition*. Oxford University Press, 1995.
- BYD Dolphin - <https://www.byd.com/br/car/dolphin>.
- HAYKIN, S. *Neural Networks and Learning Machines*. 3. ed. Pearson Education, 2009.
- K. PASSINO and S. Yurkovich, *Fuzzy Control*. Menlo Park, CA, USA: Addison-Wesley, 1998.
- L. A. ZADEH, "Fuzzy sets," *Information and Control*, vol. 8, no. 3, pp. 338-353, Jun. 1965.
- MATHWORKS. MATLAB Neural Network Toolbox™ User's Guide. The MathWorks, Inc., 2023.
- MENDEL, J. M. *Uncertain Rule-Based Fuzzy Logic Systems: Introduction and New Directions*. Prentice Hall, 2001.
- NASA Prognostics Center of Excellence (PCoE) - <https://www.nasa.gov/content/prognostics-center-of-excellence-data-set-repository>.
- PLETT, G. L. *Battery Management Systems, Volume I: Battery Modeling*. Artech House, 2015.
- ROSS, T. J. *Fuzzy Logic with Engineering Applications*. 3. ed. John Wiley & Sons, 2010.
- RENAULT Kwid E-Tech Electric - <https://www.renault.com.br/veiculos-eletricos/kwid-e-tech-electric.html>.
- RUMELHART, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536.
- TESLA Model 3 - <https://www.tesla.com/model3>.
- ZHANG, X.; WANG, C. Data-driven battery health monitoring and lifetime prediction. *Journal of Power Sources*, v. 304, p. 1–10, 2016.

CONTROLE DISTRIBUÍDO EM SUBESTAÇÕES DIGITAIS COM IEC 61850: O FUTURO DAS REDES INTELIGENTES

Pedro Mazarello de Souza
Universidade Federal de Itajubá (UNIFEI)

Leonardo de Carvalho Vidal
Instituto Federal do Rio de Janeiro (IFRJ)

RESUMO

A crescente digitalização dos sistemas elétricos tem impulsionado a adoção de normas internacionais que assegurem a interoperabilidade, segurança e eficiência operacional das instalações. A norma *IEC 61850*, amplamente reconhecida no setor elétrico, define padrões de comunicação para subestações digitais, promovendo automação, integração e padronização. Este trabalho tem como objetivo analisar a aplicação de ferramentas de gestão de projetos no gerenciamento de riscos associados à implementação da *IEC 61850* em ambientes industriais. A pesquisa foi desenvolvida por meio de revisão bibliográfica sistemática, com base em publicações científicas, normas técnicas e guias de boas práticas como o *PMBOK* do *Project Management Institute (PMI)*. Os resultados obtidos indicam que a adoção da *IEC 61850*, embora ofereça ganhos significativos em confiabilidade, flexibilidade e tempo de resposta dos sistemas elétricos, impõe desafios técnicos e organizacionais que exigem planejamento estruturado, análise de riscos e acompanhamento contínuo. A integração entre a norma *IEC 61850* e ferramentas de gestão de projetos permite identificar falhas em fases iniciais, garantir conformidade com requisitos regulatórios e otimizar os recursos empregados na automação das subestações. Este estudo contribui para a compreensão das complexidades envolvidas na digitalização do setor elétrico, propondo diretrizes para profissionais e gestores na condução de projetos de implementação dessa norma. A relevância da pesquisa reside na promoção de uma abordagem estratégica, segura e eficaz para modernização das infraestruturas energéticas brasileiras.

Palavras-chave: *IEC 61850*; subestações digitais; gestão de projetos; automação elétrica; riscos técnicos; infraestrutura energética.

INTRODUÇÃO

A modernização dos sistemas elétricos tem sido impulsionada por uma crescente demanda por eficiência, confiabilidade e interoperabilidade nas operações de geração, transmissão e distribuição de energia elétrica. Nesse cenário, o conceito de subestações digitais, aliado à normatização promovida pela *IEC 61850*, tem se destacado como um dos principais pilares da transformação digital no setor elétrico. Diferente das subestações convencionais, que se baseiam em conexões ponto a ponto entre dispositivos eletromecânicos e cablagens extensas, as subestações digitais utilizam uma arquitetura baseada em redes de comunicação industrial, permitindo a integração de Inteligência Eletrônica Distribuída (IEDs), sistemas de automação e controle em tempo real, além da redução significativa do uso de fios de cobre.

A norma *IEC 61850*, desenvolvida pela *International Electrotechnical Commission* (IEC), estabelece um modelo padronizado para a comunicação entre dispositivos em subestações, definindo protocolos como o *GOOSE* (*Generic Object Oriented Substation Event*), *MMS* (*Manufacturing Message Specification*) e *Sampled Values* (SV). A adoção desta norma permite a interoperabilidade entre equipamentos de diferentes fabricantes, a melhoria da confiabilidade operacional, a redução no tempo de comissionamento, e a viabilização de arquiteturas baseadas em controle distribuído, onde decisões automatizadas podem ser tomadas localmente, de forma segura e com baixa latência. A utilização do modelo de dados padronizado, descrito em *SCL* (*Substation Configuration Language*), também permite uma engenharia mais eficiente e uma manutenção facilitada ao longo do ciclo de vida da instalação.

Com o avanço das *smart grids* e da penetração de fontes renováveis de energia, o setor elétrico exige sistemas de automação mais ágeis, flexíveis e resilientes. Nesse contexto, a aplicação de controle distribuído torna-se estratégica, pois descentraliza o processo decisório, reduz os riscos associados à falha de um sistema central e melhora a capacidade de resposta a eventos e falhas. A norma *IEC 61850*, com seus serviços de comunicação orientados a eventos e seu modelo orientado a objetos, fornece a base técnica para que essas estratégias sejam implementadas de forma eficaz. No entanto, a sua implementação ainda encontra desafios, como a curva de aprendizado técnica,

a cibersegurança das redes digitais e a necessidade de qualificação de mão de obra para lidar com a nova arquitetura.

O Brasil já tem avançado na adoção dessa norma, com projetos pilotos e implementações comerciais em concessionárias como Furnas, CTEEP e Cemig. Contudo, ainda há muito a ser explorado em termos de padronização de práticas, testes de interoperabilidade e adaptação da norma às especificidades do sistema elétrico nacional. O presente artigo tem como objetivo apresentar uma análise crítica do controle distribuído em subestações digitais, explorando os conceitos fundamentais da *IEC 61850*, suas aplicações práticas, vantagens operacionais, e os principais desafios técnicos e operacionais que envolvem sua implementação. Para isso, será realizada uma revisão bibliográfica baseada em artigos nacionais e internacionais, além da proposição de uma estrutura de aplicação com base em boas práticas descritas na literatura.

A relevância deste estudo está em fornecer uma base teórica e aplicada para estudantes, profissionais e pesquisadores interessados em automação, proteção e controle de redes elétricas, destacando o papel estratégico que a *IEC 61850* desempenha no futuro das subestações inteligentes. A compreensão aprofundada desta norma é fundamental para acompanhar o avanço tecnológico do setor e contribuir com soluções inovadoras para a operação eficiente, segura e confiável do sistema elétrico brasileiro e global.

REFERENCIAL TEÓRICO

A crescente complexidade dos sistemas elétricos modernos, associada à diversificação das fontes de geração e à digitalização da infraestrutura, tem impulsionado a evolução da automação no setor elétrico. Nesse contexto, as subestações digitais emergem como um componente essencial das redes inteligentes (*smart grids*), oferecendo maior eficiência, flexibilidade e capacidade de monitoramento em tempo real (SILVA; SOUSA, 2019; OLIVEIRA; COSTA, 2020).

A base tecnológica que sustenta essa transformação é a norma *IEC 61850*, desenvolvida pela *International Electrotechnical Commission (IEC)*, que padroniza a comunicação entre dispositivos eletrônicos inteligentes (IEDs) em subestações. Diferente de normas anteriores, a *IEC 61850* não apenas especifica os protocolos de comunicação, mas também define um modelo de dados orientado a objetos,

uma linguagem de configuração (*SCL – Substation Configuration Language*) e um conjunto de serviços de comunicação, tais como *GOOSE*, *MMS* e *Sampled Values* (*SV*) (MACKIEWICZ, 2006; NIAZI, 2018).

O modelo de dados da *IEC 61850* é hierárquico e modular, composto por nós lógicos (*Logical Nodes*) que representam funções específicas de proteção, controle e medição, agrupados em dispositivos lógicos (*Logical Devices*). Cada nó lógico é associado a um objeto de dados padronizado, permitindo a interoperabilidade entre dispositivos de diferentes fabricantes (KASSAEI *et al.*, 2016). Essa estrutura modular permite que cada função em um IED seja tratada de forma independente, facilitando o desenvolvimento e a manutenção de sistemas complexos.

Um dos principais diferenciais da *IEC 61850* está no uso do protocolo *GOOSE* (*Generic Object Oriented Substation Event*), que permite a transmissão de mensagens orientadas a eventos de forma quase instantânea. Isso viabiliza aplicações críticas como trip instantâneo de disjuntores, intertravamentos e proteção diferencial, com tempos de resposta inferiores a 4 ms, como demonstrado por Jimeno e Eguia (2019). O protocolo *MMS* (*Manufacturing Message Specification*), por sua vez, é utilizado para operações de supervisão, controle remoto e troca de dados não críticos, como leitura de medições e comandos manuais. Já o protocolo *Sampled Values* (*SV*) é voltado para a digitalização de sinais analógicos, como correntes e tensões, permitindo a substituição de transformadores de instrumentação convencionais por transformadores digitais (*Merging Units*) (USTUN; ZEPEDA; KARSAKLI, 2020).

A estrutura funcional das subestações digitais é organizada em três níveis: nível de processo, nível de *bay* e nível de estação (Conforme indicado na Figura 1). No nível de processo, estão os dispositivos responsáveis pela medição e atuação física, como sensores, transformadores de corrente/tensão e disjuntores. No nível de *bay*, situam-se os IEDs que realizam funções de proteção, controle e intertravamento. No nível de estação, encontram-se os sistemas *SCADA*, servidores *HMI* e *gateways* de comunicação com o centro de operação (NUNES *et al.*, 2020). A *IEC 61850* facilita a comunicação entre esses níveis de forma padronizada, usando redes *Ethernet* de alta velocidade e *switches* configurados para garantir *QoS* (*Quality of Service*).

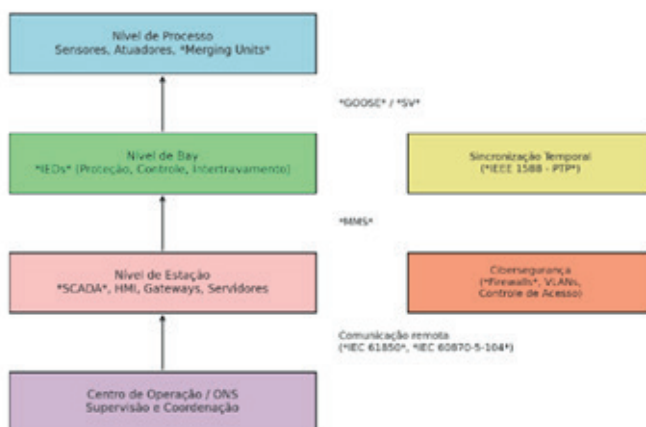
A implementação de controle distribuído em subestações digitais consiste na descentralização das funções de supervisão e comando, permitindo que os próprios IEDs tomem decisões baseadas em lógica local, sem depender de um controlador central (FINNEY, 2017). Isso melhora a resiliência e reduz o tempo de resposta a falhas, além de mitigar problemas relacionados a falhas de comunicação ou sobrecarga do sistema SCADA (ZHAO; XU, 2021). Essa arquitetura distribuída é viabilizada pela utilização dos serviços GOOSE e SV sobre redes determinísticas (geralmente com suporte a IEC 61850 Ed.2), que operam com sincronização temporal precisa via IEEE 1588 (PTP).

Autores como Brito *et al.* (2020) apontam que o uso do controle distribuído permite maior modularidade, facilidade de expansão e redução nos custos de fiação e comissionamento. No entanto, o sucesso dessa abordagem depende fortemente da interoperabilidade entre os IEDs, que, apesar de padronizada pela IEC 61850, ainda enfrenta desafios práticos, como diferenças de implementação entre fabricantes (MORAIS, 2021). Outro ponto crítico é a cibersegurança, pois a digitalização das subestações as torna vulneráveis a ataques que podem comprometer não apenas a comunicação, mas também o controle e proteção da rede elétrica (ZHAO; XU, 2021).

A adoção da IEC 61850 no Brasil tem se expandido de forma gradual. Concessionárias como Furnas, CPFL, CTEEP e Cemig têm investido em projetos piloto, estudos de interoperabilidade e treinamentos internos para a migração de sistemas legados para plataformas compatíveis com a norma (SANTOS, 2018; FREITAS; LOPES, 2020). Além disso, universidades como a UNIFEI têm contribuído com pesquisas aplicadas à validação de arquiteturas digitais e modelagem de sistemas com (MORAIS, 2021).

Por fim, destaca-se que a implementação plena do controle distribuído demanda não apenas a padronização técnica, mas também uma mudança cultural e operacional nas concessionárias, exigindo profissionais capacitados, novas estratégias de manutenção e ferramental especializado para configuração, teste e monitoramento de IEDs e redes industriais. A literatura técnica mostra que, quando corretamente implementado, o controle distribuído em subestações digitais não apenas melhora a confiabilidade e a eficiência operacional, mas também posiciona o sistema elétrico nacional para os desafios da transição energética e da digitalização completa da rede.

Figura 1 - Diagrama de Bloco de Níveis segundo a IEC 61850.



METODOLOGIA

Este trabalho adota uma abordagem teórico-aplicada para a análise da implementação do controle distribuído em subestações digitais, com base na norma *IEC 61850*, por meio de revisão técnica e estudo de modelo funcional. A proposta metodológica considera a arquitetura típica de uma subestação digital e sua estrutura hierárquica, os protocolos de comunicação definidos pela norma e as funcionalidades de automação implementadas por dispositivos eletrônicos inteligentes (IEDs). Embora o estudo não envolva diretamente experimentação em campo, ele propõe uma modelagem viável de aplicação e validação com base em simulações e práticas de mercado, sendo passível de aplicação futura em ambientes de teste.

A estrutura da subestação digital considerada neste estudo está dividida em três níveis: nível de processo, nível de bay e nível de estação (NUNES *et al.*, 2020). No nível de processo estão os sensores, atuadores e unidades de fusão (*Merging Units*) responsáveis pela aquisição e digitalização dos sinais analógicos. O nível de bay abriga os IEDs que executam as funções de proteção e controle locais. No nível de estação, localiza-se o sistema de supervisão SCADA, gateways e servidores responsáveis pela interface com os operadores e centros de controle.


Para representar o funcionamento da IEC 61850, adotou-se como base os modelos lógicos da norma, com foco nos nós lógicos (*Logical Nodes*) e nos serviços de comunicação GOOSE (*Generic Object Oriented Substation Event*) e *Sampled Values* (SV). Os nós lógicos, como PTOC, PDIS e XCBB, foram analisados quanto à sua função, estrutura e interação. Os serviços GOOSE foram avaliados quanto à sua utilização na transmissão de mensagens orientadas a eventos críticos, como o disparo de disjuntores, enquanto os SV foram estudados como alternativa digital à instrumentação tradicional (KASSAEI, 2016; JIMENO; EGUIA, 2019).

O controle distribuído proposto neste estudo é baseado na descentralização das funções de decisão, permitindo que os IEDs realizem ações de forma autônoma com base em lógicas internas e comunicações entre dispositivos vizinhos. Para isso, são utilizados os serviços GOOSE para envio de sinais *peer-to-peer* entre IEDs, sem a necessidade de intervenção do sistema central. Esse tipo de arquitetura é compatível com os conceitos de *self-healing grids*, uma vez que reduz o tempo de atuação e melhora a confiabilidade do sistema (NIAZI, 2018).

A verificação do desempenho do sistema, em termos de confiabilidade e tempo de resposta, pode ser realizada por meio de simulação computacional com ferramentas como o OMNeT++ ou o RTDS (*Real-Time Digital Simulator*). Essas plataformas permitem modelar o comportamento dos IEDs, emular o tráfego de rede via GOOSE e SV, e avaliar a resposta do sistema frente a falhas simuladas. Além disso, propõe-se o uso de software como o IEDScout ou o System Configuration Tool (SCT) para a configuração e leitura de dados SCL, permitindo a geração de arquivos .icd, .cid e .scl, essenciais para a interoperabilidade (FINNEY, 2017).

O modelo proposto para validação do controle distribuído segue o seguinte fluxo: (1) definição da arquitetura funcional da subestação digital conforme IEC 61850; (2) atribuição dos Logical Nodes aos IEDs conforme suas funções; (3) configuração dos serviços GOOSE e SV em rede Ethernet com suporte a VLAN e QoS; (4) simulação de eventos e análise do comportamento dos IEDs em tempo real; (5) avaliação do tempo de atuação, perda de pacotes e robustez da rede (Figura 2).

Figura 2 - Fluxograma para Validação do Controle Distribuído.



Para garantir a sincronização temporal necessária à operação dos IEDs e à amostragem dos sinais analógicos, considera-se também a implementação do protocolo *IEEE 1588 (PTP – Precision Time Protocol)*, fundamental para sistemas baseados em *Sampled Values* (ZHAO; XU, 2021). A precisão da sincronização é essencial para o alinhamento entre dados de corrente e tensão, evitando erros nas funções de proteção diferencial e de distância.

Durante o processo de modelagem e análise, também são consideradas diretrizes da norma *IEC 61850 Edition 2*, que amplia a cobertura de funções, melhora a interoperabilidade entre fabricantes e oferece suporte a cenários mais complexos de controle e proteção. Essa versão é especialmente relevante para subestações com topologia dinâmica ou integração de geração distribuída.

A metodologia proposta neste artigo se justifica pela sua aplicabilidade em ambientes reais, pela aderência às práticas internacionais e pela sua capacidade de fornecer uma base sólida para desenvolvimento de sistemas de automação elétrica resilientes, seguros e interoperáveis. O modelo adotado, embora não aplicado diretamente em campo neste trabalho, oferece suporte para futuras aplicações em ambientes de teste laboratoriais, bancadas de simulação com *hardware-in-the-loop (HIL)* e projetos de pesquisa em parceria com concessionárias e centros de pesquisa.

RESULTADOS E DISCUSSÃO

A adoção do controle distribuído em subestações digitais conforme os preceitos da norma *IEC 61850* representa uma transformação fundamental na forma como se realizam as operações de proteção e automação no setor elétrico. A arquitetura distribuída baseada em comunicação digital por *Ethernet*, serviços *GOOSE* (*Generic Object Oriented Substation Event*) e *Sampled Values* (*SV*), bem como o uso de modelos lógicos padronizados em dispositivos eletrônicos inteligentes (*IEDs*), resulta em uma série de benefícios técnicos e operacionais esperados, ao mesmo tempo em que impõe desafios de padronização, segurança e qualificação profissional.

Entre os principais resultados esperados destaca-se a redução no tempo de atuação dos sistemas de proteção. Estudos apontam que, com o uso adequado do protocolo *GOOSE*, é possível atingir tempos de atuação inferiores a 4 milissegundos, uma melhoria significativa em comparação com sistemas convencionais baseados em contatos físicos e relés analógicos (KASSAEI, 2016). Essa velocidade permite uma atuação quase imediata em caso de falhas, como curtos-circuitos, mitigando riscos e preservando a integridade dos ativos da rede.

Os *IEDs* operam de forma autônoma, realizando ações de comando e proteção diretamente, com base em sinais recebidos via rede local, sem depender de decisões de um sistema central.

Além da rapidez na atuação, a resiliência operacional é significativamente aumentada. A lógica distribuída permite que os dispositivos continuem operando mesmo diante da perda de comunicação com o nível de supervisão ou com partes do sistema, garantindo maior disponibilidade e tolerância a falhas (NIAZI *et al.*, 2018). Cada *IED* é configurado com lógicas internas baseadas em blocos funcionais padronizados (*Logical Nodes*), como *PDIS* (proteção de distância), *PTOC* (sobrecorrente), e *XCBB* (comando de disjuntor), capazes de interpretar eventos locais e realizar ações corretivas. Essa arquitetura peer-to-peer reduz a dependência do *SCADA* e do servidor central, o que é fundamental em contingências.

No campo da engenharia e operação, outro impacto relevante é a redução do tempo de comissionamento e manutenção, que pode chegar a 30%, segundo Moraes (2021). Isso ocorre devido à padronização da estrutura lógica

dos sistemas de controle e proteção, configurável por meio da linguagem *SCL (Substation Configuration Language)*, que define e integra as funções dos IEDs em arquivos digitais como .icd, .cid e .scd. Com isso, os processos de documentação, testes e validações são otimizados, evitando erros comuns em conexões físicas e facilitando a rastreabilidade e o reaproveitamento de projetos anteriores (FINNEY, 2017).

Em termos de interoperabilidade, um dos pilares teóricos da IEC 61850, os resultados apontam avanços significativos, mas ainda existem desafios. Apesar da norma prever modelos de dados universais e serviços padronizados, na prática existem variações entre fabricantes, principalmente no que se refere ao suporte a versões diferentes da norma (Edition 1 vs. Edition 2), interpretação de serviços *GOOSE/SV* e estruturas internas dos *Logical Nodes* (JIMENO; EGUÍA, 2019). Ensaios de interoperabilidade realizados por concessionárias e laboratórios especializados, como os descritos por Finney (2017), mostram que, embora a troca de dados entre dispositivos de diferentes marcas seja possível, requer esforço técnico, análise de logs, ajustes nos arquivos *SCL* e testes exaustivos.

No tocante à segurança cibernética, a substituição da fiação física por uma infraestrutura de rede Ethernet aberta introduz uma nova superfície de risco. Os serviços *GOOSE* e *SV*, originalmente sem criptografia ou autenticação, podem ser alvos de falsificação ou interceptação, caso não haja medidas de proteção adicionais, como *VLANs*, *firewalls* industriais, gerenciamento de acesso e sincronização segura via *IEEE 1588* (ZHAO; XU, 2021). Portanto, embora a digitalização traga ganhos substanciais, ela exige uma reconfiguração das práticas de segurança no setor elétrico, que historicamente se baseavam em isolamento físico.

Do ponto de vista prático, o controle distribuído já encontra aplicações reais no Brasil. Em estudo de caso publicado por Santos (2018), a migração de uma subestação convencional para digital resultou na eliminação de mais de 2.000 metros de cabeamento de controle, além da diminuição de 15% no tempo de implantação do projeto. A nova estrutura possibilitou manutenções mais rápidas, documentação digitalizada e diagnósticos remotos mais precisos. Similarmente, projetos de Furnas e CPFL têm demonstrado o uso de IEDs com comunicação *GOOSE* e *SV*, aumentando a confiabilidade de sistemas de

proteção de linhas e barras, especialmente em ambientes críticos com geração distribuída (OLIVEIRA; COSTA, 2020).

É importante destacar que a curva de aprendizado para o uso eficiente da *IEC 61850* ainda representa um obstáculo considerável. A transição de esquemas baseados em diagramas unifilares e contatos físicos para um modelo abstrato e digital requer mudanças na cultura organizacional e formação especializada dos engenheiros (MORAIS, 2021). Muitos profissionais ainda se deparam com dificuldades na interpretação dos *Logical Nodes*, na configuração dos arquivos *SCL* e no diagnóstico de eventos via rede. Essa lacuna evidencia a necessidade de reformular a capacitação técnica em cursos de Engenharia Elétrica e investir em treinamentos práticos, como ensaios de interoperabilidade, simulações com ferramentas como *OMNeT++*, *RTDS*, *IEDScout* e ferramentas de configuração de fabricantes.

Outra perspectiva discutida é a escalabilidade e a capacidade de expansão modular proporcionada pelo modelo distribuído. Subestações digitais com *IEC 61850* podem ser ampliadas com menor impacto físico e lógico, uma vez que novos IEDs podem ser integrados à rede com simples atualizações nos arquivos de configuração e reorganização da lógica de comunicação. Isso é especialmente vantajoso em sistemas que integram fontes intermitentes de energia, como eólica e solar, e demandam respostas rápidas a variações de carga e contingências (USTUN *et al.*, 2020).

A discussão revela, portanto, que embora a tecnologia esteja madura e aplicada em diversos contextos internacionais e nacionais, sua consolidação como padrão no Brasil ainda depende de fatores como: (i) regulamentação clara por parte de agências reguladoras como ANEEL e ONS; (ii) maior padronização entre os fabricantes de IEDs; (iii) disseminação de ferramentas de diagnóstico e teste; e (iv) inclusão efetiva do tema nas políticas de pesquisa, desenvolvimento e inovação.

Com base na análise dos resultados, observa-se que a norma *IEC 61850*, aliada ao controle distribuído, oferece um caminho promissor e sustentável para a evolução das redes inteligentes, com aplicações viáveis em projetos *greenfield* e *retrofit*. Os ganhos em performance, redução de custos, interoperabilidade e automação justificam o investimento na transição, desde que acompanhados de um planejamento estratégico que inclua segurança, formação e validação

técnica. A maturação desse modelo, tanto em universidades quanto em concessionárias, é essencial para preparar o sistema elétrico brasileiro para os desafios da transição energética, digitalização e descentralização da geração.

CONCLUSÃO

A presente pesquisa evidenciou a importância estratégica da norma *IEC 61850* na modernização das subestações elétricas por meio da implementação de controle distribuído, destacando sua aplicabilidade dentro do contexto das redes inteligentes (*smart grids*). A transição de arquiteturas centralizadas para estruturas descentralizadas, baseada na interoperabilidade entre IEDs, no uso de protocolos orientados a eventos como *GOOSE* e *Sampled Values*, e na padronização promovida pela linguagem *SCL*, representa um marco no avanço da automação do setor elétrico.

Conforme demonstrado ao longo do artigo, os benefícios técnicos e operacionais da adoção dessa tecnologia incluem a redução do tempo de atuação dos sistemas de proteção, maior resiliência frente a falhas de comunicação, simplificação do comissionamento e manutenção, além da escalabilidade para expansão futura das instalações. O uso do controle distribuído também contribui para uma maior flexibilidade no gerenciamento da rede, sendo compatível com os desafios da geração distribuída, mobilidade elétrica, uso racional de recursos, e resposta rápida a contingências.

No entanto, a discussão também mostrou que a adoção plena do modelo enfrenta obstáculos importantes, como as dificuldades de interoperabilidade entre diferentes fabricantes, as exigências de cibersegurança, e a necessidade de capacitação técnica contínua. Esses desafios não invalidam o potencial da *IEC 61850*, mas apontam para a importância de políticas de padronização, investimento em P&D e formação profissional focada em tecnologias digitais.

A proposta metodológica baseada em modelagem funcional, simulação e análise de protocolos mostrou-se eficaz para compreender a lógica de funcionamento do controle distribuído, sendo aplicável tanto em ambientes acadêmicos quanto como base para projetos industriais. Os resultados obtidos e as aplicações práticas levantadas apontam que a *IEC 61850* não é apenas uma norma técnica, mas um vetor de transformação digital no setor elétrico.

Portanto, conclui-se que o controle distribuído em subestações digitais com IEC 61850 constitui um caminho sólido, tecnicamente viável e alinhado com os princípios da inovação e da sustentabilidade, sendo altamente relevante para profissionais e pesquisadores da Engenharia Elétrica. Trabalhos futuros podem ampliar esta pesquisa por meio de simulações em tempo real, testes de interoperabilidade entre IEDs, e estudos de segurança cibernética, consolidando ainda mais a base técnica para o futuro das redes elétricas inteligentes no Brasil e no mundo.

REFERÊNCIAS

BRITO, R. C.; ARAÚJO, F. L.; VASCONCELOS, R. P. Aplicação da norma IEC 61850 na automação de subestações digitais. *Revista Brasileira de Energia*, v. 26, n. 2, p. 123–134, 2020.

FINNEY, D.; RATHORE, A.; PALMER, A. *Interoperability Testing of IEC 61850 Based Systems*. In: CIGRÉ Session Papers. Paris: CIGRÉ, 2017.

FREITAS, D. R.; LOPES, M. A. Desafios na Implementação de Subestações Digitais no Brasil com a Norma IEC 61850. Simpósio Brasileiro de Sistemas Elétricos (SBSE), 2020. Disponível em: <https://ieeexplore.ieee.org/document/9259283>. Acesso em: 19 jun. 2025.

IEC – International Electrotechnical Commission. *IEC 61850: Communication networks and systems for power utility automation*. Geneva: IEC, 2013. Parte 7-1 a 9-2.

JIMENO, J.; EGUIA, P. *Distributed Protection and Control Applications with IEC 61850*. *IEEE Latin America Transactions*, v. 17, n. 6, p. 979–986, 2019. DOI: 10.1109/TLA.2019.8837001.

KASSAEI, S. M.; KEYHANI, A.; STRAYER, M. L. *Implementation of IEC 61850 in Protection and Control Systems*. *IEEE Transactions on Smart Grid*, v. 7, n. 1, p. 129–138, 2016. DOI: 10.1109/TSG.2015.2435516.

MACKIEWICZ, R. Overview of IEC 61850 and Benefits. In: *IEEE Power Systems Conference and Exposition*. Atlanta: IEEE, 2006. DOI: 10.1109/PSCE.2006.296319.

MARTINS, G. F. Segurança cibernética aplicada a sistemas elétricos com IEC 61850. *Revista Engenharia Elétrica em Foco*, v. 5, n. 2, p. 77–89, 2021.

MORAIS, M. V. Avanços e desafios na digitalização de subestações com IEC 61850 no Brasil. *Revista Técnica da CEMIG*, n. 102, p. 45–59, 2021.

NIAZI, M.; LIAO, Y.; MAJUMDER, R. *Distributed Intelligent Control for Smart Grids Using IEC 61850*. *IEEE Transactions on Industrial Informatics*, v. 14, n. 3, p. 1044–1055, 2018. DOI: 10.1109/TII.2017.2711447.

NUNES, R. F.; CARVALHO, M. C.; DIAS, A. F. Subestações digitais no contexto brasileiro: experiências e aprendizados. Seminário Nacional de Produção e Transmissão de Energia Elétrica (SNPTEE), 2020.

OLIVEIRA, R. C.; COSTA, J. P. Estudo de Caso de Retrofit em Subestação com Aplicação de IEC 61850. *Revista Técnico-Científica de Engenharia Elétrica*, v. 12, n. 3, p. 89–101, 2020.

SANTOS, A. M. Case Study: Implantação de Subestação Digital com IEC 61850 em Furnas. *Revista Engenharia e Tecnologia*, v. 19, n. 1, p. 12–20, 2018.

SILVA, C. A.; SOUSA, R. F. Comunicação em subestações digitais: GOOSE, SV e MMS segundo a IEC 61850. *Revista Eletrônica de Engenharia Elétrica*, v. 14, n. 2, p. 55–65, 2019.

USTUN, T. S.; ZEPEDA, J. C.; KARSAKLI, A. *Design and Evaluation of GOOSE Messaging and Sampled Values in IEC 61850 Based Substation. Journal of Modern Power Systems and Clean Energy*, v. 8, n. 4, p. 663–673, 2020. DOI: 10.35833/MPCE.2019.000236.

ZHAO, M.; XU, Y. *Cybersecurity Implications of IEC 61850 in Smart Grids. IEEE Access*, v. 9, p. 108572–108584, 2021. DOI: 10.1109/ACCESS.2021.3102160.

ANÁLISE DA QUALIDADE DA ÁGUA UTILIZANDO UM MODELO *FUZZY*

Leiziane Aparecida Tavares Pereira
Instituto Federal do Rio de Janeiro (IFRJ)

Juliana Ribas Monteiro
Instituto Federal do Rio de Janeiro (IFRJ)

Leonardo de Carvalho Vidal
Instituto Federal do Rio de Janeiro (IFRJ)

RESUMO

O aumento da poluição e da demanda por recursos hídricos intensificou a preocupação com a qualidade da água. Resíduos domésticos, poluentes industriais, esgoto inadequado e mudanças climáticas são fatores que agravam a degradação desse recurso, tornando o controle e o saneamento grandes desafios, especialmente em regiões urbanas e vulneráveis. **Objetivo:** O artigo apresenta a aplicação de um modelo *fuzzy* para a análise da qualidade da água, considerando a incerteza e a imprecisão dos dados ambientais. Desenvolvido na plataforma *Matlab®/Simulink*, o modelo integra os parâmetros condutividade, cor, *pH* e turbidez em um sistema de inferência *fuzzy*, permitindo a classificação da água quanto à sua adequação ao consumo humano. **Métodos:** O modelo foi estruturado com base em funções de pertinência e regras *fuzzy* previamente definidas, estabelecendo relações lógicas entre os parâmetros analisados e a qualidade da água. Para verificar sua eficácia, foram realizadas simulações computacionais, comparando os resultados obtidos com o Índice de Qualidade da Água (IQA) tradicional. **Resultados:** Os resultados demonstraram elevada consistência entre os dois métodos, embora pequenas variações tenham sido observadas nos valores numéricos, a classificação final da qualidade da água apresentou uma taxa de acerto de 98% em relação às categorias de qualidade do IQA. Esse desempenho evidencia a capacidade do sistema *fuzzy* em reproduzir, de forma confiável, os critérios estabelecidos pelo método clássico, oferecendo maior flexibilidade na representação da incerteza e na integração das variáveis de entrada. Assim, o modelo proposto mostra-se uma alternativa eficiente para o apoio à avaliação e ao monitoramento da qualidade da água.

Palavras-chave: Qualidade da água; modelo *Fuzzy*; simulação computacional.

INTRODUÇÃO

A automação tem avançado de forma contínua, desempenhando um papel cada vez mais relevante, desde a execução de tarefas simples até as mais complexas. E nesse contexto, vem sendo a cada dia mais utilizada para realizar o controle dos processos, em que as situações necessitam de uma abordagem mais flexível para o tratamento dos dados, sendo extremamente útil quando os sistemas são dinâmicos ou quando a tomada de decisão envolve julgamentos humanos.

Os princípios da lógica *fuzzy* foram primeiramente gerados por Jan Lukasiewicz (1878-1956), que desenvolveu e introduziu os conjuntos com graus de pertinência combinados com a lógica clássica em 1920. Na década de 60, Zadeh, um professor de Ciências da Computação da Universidade da Califórnia, publicou o primeiro artigo sobre a lógica *fuzzy*, Merli *et al.* (2011).

Segundo Zadeh (1994), a lógica *fuzzy* promoveu uma revolução no campo da inteligência artificial, ao viabilizar o desenvolvimento de sistemas capazes de lidar com incertezas e processar informações imprecisas de maneira eficaz. Essa abordagem tem sido amplamente utilizada em aplicações industriais, destacando-se em sistemas de controle e em soluções de apoio à tomada de decisão, onde a flexibilidade e a robustez são essenciais para operar em ambientes complexos. Zadeh observou que as regras presentes em nosso cotidiano não poderiam ser utilizadas e explicadas pelas pessoas que as usavam, a partir desta ideia ele começou a desenvolver a lógica *fuzzy*.

A lógica *fuzzy*, apesar de seu nome, que remete a algo difuso ou nebuloso, é fundamentada em regras precisas e bem definidas. Um modelo *fuzzy* busca reproduzir, de maneira fiel, o raciocínio humano em processos e operações, que frequentemente apresentam alta complexidade, Vidal (2015). Segundo Chen *et al.* (2024), os sistemas *fuzzy* operam com base em um conjunto de regras linguísticas que permitem a transformação de variáveis de entrada em decisões de saída. Essa abordagem é especialmente eficaz em cenários que demandam raciocínio próximo ao humano, pois oferece uma maneira flexível e intuitiva de lidar com incertezas e ambiguidade.

Esta lógica se difere dos sistemas lógicos tradicionais por não ser um raciocínio exato que admite apenas valores booleanos, como verdadeiro ou

falso, 1 ou 0. Os conjuntos *fuzzy* são capazes de variar os valores entre 1 e 0, desta forma, uma pertinência com valor 0,6 pode ser considerada como “meio verdade”, 0,9 pode ser considerada como “quase verdade” e 0,1 como “quase falso”, por exemplo, Silva *et al.* (2005).

De acordo com Amendola *et al.* (2005), a versatilidade da teoria *fuzzy* reside na capacidade de modelar e manipular matematicamente informações vagas e imprecisas, comuns na linguagem humana. Isso permite que especialistas, mesmo sem formação matemática, possam caracterizar os processos estudados de forma prática e acessível.

Nos últimos anos, aplicações baseadas em lógica *fuzzy* têm demonstrado resultados promissores em diferentes contextos, Mishra *et al.* (2024), desenvolveram um sistema baseado em Sistema de Informação Geográfica e lógica *fuzzy* para mapear a qualidade da água em uma bacia hidrográfica. Consideraram parâmetros como turbidez, oxigênio dissolvido e coliformes. A referência Vásquez *et al.* (2020), pesquisadores implementaram um protótipo de planta de tratamento de água com controle de *pH* baseado em lógica *fuzzy* para remoção de arsênio. O sistema conseguiu manter o *pH* ideal e remover o arsênio abaixo dos limites recomendados pela Organização Mundial da Saúde, demonstrando a eficácia da lógica *fuzzy* em processos de tratamento de água. Outro estudo avaliou a qualidade da água subterrânea para diversos usos, incluindo industrial, utilizando um índice baseado em lógica *fuzzy*. A abordagem permitiu integrar múltiplos parâmetros e fornecer uma avaliação mais precisa da adequação da água para uso industrial, Kumae, *et al.* (2024).

Segundo referências como Mandani (1974) e Cordon *et al.* (2001), a lógica *fuzzy* pode ser aplicada em uma ampla variedade de processos, permitindo a modelagem de sistemas complexos e imprecisos por meio de regras baseadas em lógica aproximativa. Suas aplicações incluem o controle de processos industriais, como sistemas de ar-condicionado inteligente, estufas agrícolas, ajuste de velocidade de motores e controle de pressão em sistemas hidráulicos; na engenharia e robótica, sendo utilizada no controle de robôs autônomos, em sistemas de frenagem ABS e em suspensões ativas de veículos; na saúde e medicina, auxiliando no diagnóstico de doenças como diabetes e câncer, no apoio à decisão clínica e no controle de próteses inteligentes; na inteligência artificial e computação, com sistemas especialistas para tomada de decisão,

processamento de imagens para suavização de bordas e segmentação, além do reconhecimento de padrões como voz, escrita e rostos; na economia e finanças, em análises de risco e investimento, classificação de crédito e precificação dinâmica baseada na demanda; em eletrônicos de consumo, como câmeras digitais com ajuste automático de foco e exposição, eletrodomésticos inteligentes que otimizam o consumo de energia e assistentes virtuais capazes de interpretar comandos de voz imprecisos; e na agricultura e meio ambiente, sendo aplicada na previsão climática, otimização da irrigação e monitoramento da qualidade da água.

O uso de suas regras e variáveis linguísticas permite desenvolver um sistema de controle da qualidade da água com várias vantagens. Entre elas, destacam-se a facilidade na especificação das regras de controle, a simplificação do modelo do processo, o uso de uma linguagem mais simples e natural, além da capacidade de realizar o controle com múltiplos objetivos distintos, Garcia *et al.* (2012). O projeto se propõe a realizar um modelo *fuzzy* que seja capaz de fazer o monitoramento da qualidade da água, através de algumas variáveis de entrada, como valores de *pH*, turbidez, cor e condutividade da água.

A água é uma das substâncias mais comuns e abundantes do planeta, e está presente em todos os aspectos da vida humana. Por isso, ela se torna um recurso natural essencial, utilizado diariamente em diversas tarefas e indispensável para a sobrevivência de inúmeras espécies de seres vivos e plantas. A água devidamente tratada desempenha um papel fundamental na manutenção da saúde humana, contribuindo para a prevenção de doenças e a proteção do organismo, Paschoal *et al.* (2012).

A água tornou-se um recurso estratégico para qualquer país, devido a fatores como o crescimento populacional, a expansão urbana, a industrialização, a agricultura, a pecuária e a geração de energia elétrica. O aumento na demanda resultou na necessidade de volumes cada vez maiores de água. Nos últimos 60 anos, esses processos foram acompanhados por um ciclo de poluição (para cada mil litros de água utilizados, outros dez mil são contaminados), o que torna a água um recurso cada vez mais precioso.

A água utilizada pode conter diferentes tipos de contaminações, que alteram suas características físicas, químicas e biológicas. Quando esses parâmetros estão fora dos padrões estabelecidos pela legislação, indica-se que a

água é inadequada para consumo Brasil *et al.* (2011). Parâmetros físicos, como a cor; químicos, como *pH* e condutividade; e biológicos, como os coliformes (analisados por meio da turbidez), são considerados neste estudo. Seus valores serão utilizados como parâmetros na simulação apresentada neste artigo através da lógica *fuzzy*.

MÉTODOS E REVISÃO DOS CONCEITOS

Qualidade da Água

Os parâmetros de qualidade da água são indicadores essenciais para avaliar a adequação da água para diferentes usos, como consumo humano, industrial e agrícola. Esses parâmetros incluem aspectos físicos, químicos e biológicos, como *pH*, turbidez, cor, condutividade elétrica e presença de micro-organismos. A análise desses fatores é fundamental para monitorar a segurança da água e garantir que esteja dentro dos padrões estabelecidos pela legislação, preservando a saúde pública e o equilíbrio ambiental.

Segundo a revista Tratamento de Água (2015), a condutividade elétrica da água refere-se à sua capacidade de conduzir corrente elétrica, que está diretamente relacionada à presença de íons dissolvidos, partículas eletricamente carregadas. Quanto maior a concentração de íons, maior será a condutividade elétrica, o que reflete a quantidade de substâncias dissolvidas e, consequentemente, a qualidade da água. A cor da água é determinada pela presença de substâncias dissolvidas que podem alterar sua coloração, sendo comumente influenciada por elementos como ferro e manganês, pela decomposição de matéria orgânica de origem vegetal, pela presença de algas ou ainda pela introdução de efluentes industriais e domésticos. Conforme os padrões de potabilidade, a cor deve apresentar valores inferiores a 5 unidades para que a água seja considerada apropriada para o consumo. O *pH*, que representa o potencial hidrogeniônico e o equilíbrio entre íons H^+ e OH^- , varia entre 0 e 14, sendo recomendado pela Organização Mundial da Saúde e pela legislação de diversos países que a água potável apresente *pH* entre 6,5 e 8,5. Este parâmetro é influenciado por características naturais da água, mas pode sofrer alterações devido à introdução de resíduos. Valores baixos de *pH* tornam a água corrosiva,

enquanto valores elevados favorecem a formação de incrustações em tubulações; além disso, o *pH* é essencial para a vida aquática, sendo recomendada a faixa entre 6 e 9 para manutenção de um ecossistema equilibrado. Já a turbidez da água indica a presença de partículas em suspensão, como argila, silte, substâncias orgânicas finamente divididas e micro-organismos. Para que a água seja considerada potável, a turbidez deve ser inferior a 1 unidade, garantindo assim a sua qualidade e segurança para o consumo humano. De forma geral, para que a água atenda aos padrões ideais de potabilidade, é necessário que a condutividade esteja entre 250 e 500 $\mu\text{S}/\text{cm}$, a cor seja inferior a 5 uH, o *pH* permaneça entre 6,5 e 8,5 e a turbidez mantenha-se abaixo de 1 NTU, normalmente entre 0,1 e 1,0.

O Índice de Qualidade da Água (IQA) é calculado utilizando o método do produto ponderado, no qual cada variável básica da qualidade da água contribui proporcionalmente à sua relevância no índice final. Para o cálculo é usada a equação (1):

$$IQA = \prod_{i=1}^n qi^{\omega i} \quad (1)$$

Onde:

qi: Qualidade parcial da água associada ao parâmetro *i*, que é expressa em uma escala padronizada (geralmente de 0 a 100).

ωi : Peso atribuído ao parâmetro *i*, representando sua importância relativa no cálculo do índice.

v: Número total de parâmetros considerados.

[*i*]: Representa o produto de todos os termos.

A equação (2) representa a soma dos pesos atribuídos a cada parâmetro utilizado no cálculo do IQA, funcionando como uma etapa de normalização.

$$\sum_{i=1}^n \omega i \quad i = 1 \quad (2)$$

Onde:

ωi : Peso atribuído ao parâmetro *i*, que reflete sua importância relativa no índice.

v: Número total de parâmetros avaliados.

Σ : Representa a soma dos pesos.

Essa abordagem assegura que nenhum parâmetro exerça influência excessiva ou insignificante no resultado final, permitindo que o IQA seja matematicamente consistente e comparável, mesmo quando diferentes conjuntos de

variáveis são utilizados. A atribuição dos pesos é feita com base na relevância de cada parâmetro para a qualidade da água, conforme estabelecido por órgãos ambientais e estudos técnicos. Por exemplo, a condutividade e a cor receberam pesos de 0,40 cada, devido à sua alta relevância para a saúde pública e para a vida aquática. O *pH*, com peso 0,12, influencia a solubilidade e a toxicidade de substâncias químicas na água, enquanto turbidez, com peso 0,08, indica o nível de matéria orgânica biodegradável presente. Esses valores foram definidos com base em estudos como a Qualidade da água. [S.l.]: [s.n.], (2014), que garantem a consistência e comparabilidade do índice.

Com base nesse cálculo, é possível determinar a classificação da água quanto à sua adequação ao consumo humano, conforme os critérios utilizados na Região Sudeste, apresentados na Tabela 1.

Tabela 1 - Faixa de Valores da Qualidade da água.

Categoria	Ponderação
Ótima	$91 < IQA \leq 100$
Boa	$71 < IQA \leq 90$
Regular	$51 < IQA \leq 70$
Ruim	$26 < IQA \leq 50$
Péssima	$0 < IQA \leq 25$


Fonte: Adaptado de (Qualidade da Água, 2014).

Lógica Fuzzy

A lógica *fuzzy* surgiu da necessidade de resolver o que as lógicas tradicionais ou formais tinham uma dificuldade de representar com apenas a lógica binária. Segundo Zanneti *et al.* (2016), a lógica nebulosa lida com incertezas, permitindo o processamento de dados imprecisos. Seus graus de pertinência podem ser interpretados como medidas que indicam a possibilidade de um elemento pertencer a um conjunto *fuzzy*. Em outras palavras, a lógica *fuzzy* é capaz de avaliar a existência de valores intermediários entre os extremos de pertinência e não pertinência a esses conjuntos.

A Figura 1 apresenta uma pequena comparação entre a lógica formal/tradicional e lógica *fuzzy*.

Figura 1 - Diferença entre a lógica formal e fuzzy.




Fonte: Adaptado de (TOLEDO, 2004).

A base de regras tem a função de traduzir matematicamente as informações que compõem a base de conhecimento do sistema *fuzzy*. As variáveis fuzzificadas devem, então, passar pelo processo de defuzzificação das variáveis de saída, o qual pode ser realizado por meio de alguns métodos como o dos máximos, a média dos máximos e o método centroide, Barros *et al.* (2006).

Segundo, De Godoy *et al.* (2020), os controladores *fuzzy* consistem em uma base de dados/conhecimento, que servem como entrada do modelo, onde são armazenados os valores verdadeiros. Em seguida, ocorre o processamento, que é responsável por encontrar a solução para o problema proposto. Esse processamento é subdividido em três etapas: o processo de fuzzificação, os procedimentos de inferência e, por fim, o processo de defuzzificação.

A Figura 2 apresenta o esquema de um modelo *fuzzy*.

Figura 2 - Esquema de um modelo *fuzzy*.



Fonte: Adaptado de (GOMIDE, 1994).

Exemplificando a Figura 2 de acordo Barros *et al.* (2004)

- **Base de conhecimento:** são as regras, as estratégias de controle e suas metas;
- **Base de dados:** armazena as definições necessárias, entradas, saídas, definições das funções de pertinência;
- **Procedimento de inferência:** processa os dados *fuzzy* de entrada junto com as regras;
- **Fuzificação:** pega os valores de entrada, faz um escalonamento e transforma os números em conjuntos *fuzzy*, para se tornarem variáveis linguísticas;
- **Desfuzificação:** transformam as ações do modelo *fuzzy* em ações não *fuzzy*, volta os valores para as variáveis.

A teoria dos conjuntos clássica é binária, o elemento pertence ou não pertence a um conjunto, como por exemplo:

$$X_A(x) = \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{se } x \notin A \end{cases} \quad (3)$$

Seja U o conjunto universo, A um subconjunto de U , e x um elemento pertencente a U . A função característica, nesse caso, é definida como um mapeamento que associa cada elemento do conjunto universo U a um valor no conjunto $\{0,1\}$. Esse valor indica se o elemento x pertence (1) ou não (0) ao subconjunto A .

$$X: U \rightarrow [0,1] \quad (4)$$

Um conjunto *fuzzy* A , definido em um conjunto universo U , é representado como um conjunto de pares ordenados $(x, \mu_A(x))$, onde x é um elemento genérico de U e $\mu_A(x)$ é o grau de pertinência desse elemento ao conjunto *fuzzy* A . O grau de pertinência $\mu_A(x)$ é uma função que associa a cada elemento x um valor no intervalo contínuo $[0,1]$, indicando o nível de pertencimento de x ao conjunto A .

$$A = \{x, X_A(x) | x \in U\} \quad (5)$$

Quanto à representação de um conjunto *fuzzy*, se ele é discreto pode-se simplesmente enumerar os seus elementos juntamente com seus graus de pertinência:

$$A = \sum_i \frac{x_A(x_i)}{x_i} \quad (6)$$

Onde a somatória se refere a operação união (disjunção) e a notação $\frac{x_A(x_i)}{x_i}$ se refere ao elemento que pertence ao conjunto *fuzzy* A com grau $X_A(x_i)$.

Proposta

No desenvolvimento da simulação computacional, utilizou-se o *software Matlab®*. Por meio da *Simulink Library*, foi possível criar um modelo para a análise da qualidade da água.


A modelagem foi realizada no ambiente Simulink, utilizando a ferramenta *Fuzzy Logic Designer* para representar quatro variáveis de entrada, correspondentes aos parâmetros considerados na avaliação da qualidade da água. O sistema foi estruturado com base em uma lógica *fuzzy* do tipo Mamdani, adotando

o método do centroide como técnica de desfuzificação. As regras *fuzzy* foram definidas previamente, de modo a refletir o comportamento esperado entre os parâmetros de entrada e os níveis de qualidade. Como resultado, o sistema gerou uma saída representando o grau de adequação da água para o consumo humano, permitindo uma interpretação qualitativa baseada nos critérios estabelecidos.

As funções do tipo Mamdani são capazes de processar múltiplas entradas (*inputs*), cada uma associada às suas respectivas funções de pertinência e regras, gerando uma única saída (*output*). Esse método é amplamente utilizado devido à sua simplicidade estrutural, baseada em operações de mínimo-máximo. As regras de inferência seguem o formato clássico, permitindo uma implementação eficiente e eficaz na resolução de problemas complexos como por exemplo:

Se x é A e y é B então z é C (7)


Figura 3 - Toolbox Fuzzy do Matlab®.



Fonte: Autora, 2025.


Nas Figuras 4, 5, 6 e 7 têm-se as entradas e suas funções de pertinência para realizar toda a análise. Na Figura 8 tem-se a saída.

Figura 4 - Função de pertinência "condutividade".




Fonte: Autora, 2025.

Figura 5 - Função de pertinência "cor".




Fonte: Autora, 2025.

Figura 6 - Função de pertinência "pH".




Fonte: Autora, 2025.

Figura 7 - Função de pertinência "turbidez"



Fonte: Autora, 2025.

Figura 8 - Função de pertinência de saída "qualidade_da_água"



Fonte: Autora, 2025.

Após a configuração do modelo *fuzzy*, foram definidas 81 regras utilizando um sistema de inferência baseado na lógica *AND*. Esse sistema avalia a parte "SE" de cada regra, determinando o menor dos dois valores de pertinência envolvidos, o que representa o grau de adequação da regra ao estado atual do sistema. Com base nessas regras, conforme apresentado na Tabela 2, o modelo *fuzzy* realizou a análise da qualidade da água.

Tabela 2 - Regras Fuzzy.

Regras inseridas no modelo Fuzzy (AND)					
Combinação das variáveis: Condutividade, Cor, pH e Turbidez					
Regra	Se	Se	Se	Se	Então
	Condutividade	Cor	pH	Turbidez	Definição
1	Fraco	Claro	Ácido	Baixo	Ruim
2	Fraco	Claro	Ácido	Médio	Ruim
3	Fraco	Claro	Ácido	Alto	Ruim
4	Fraco	Claro	Neutro	Baixo	Ótima
5	Fraco	Claro	Neutro	Médio	Regular
6	Fraco	Claro	Neutro	Alto	Ruim
7	Fraco	Claro	Alcalino	Baixo	Boa
8	Fraco	Claro	Alcalino	Médio	Regular
9	Fraco	Claro	Alcalino	Alto	Ruim
10	Fraco	Moderado	Ácido	Baixo	Ruim
11	Fraco	Moderado	Ácido	Médio	Ruim
12	Fraco	Moderado	Ácido	Alto	Péssima
13	Fraco	Moderado	Neutro	Baixo	Regular
14	Fraco	Moderado	Neutro	Médio	Regular
15	Fraco	Moderado	Neutro	Alto	Ruim
16	Fraco	Moderado	Alcalino	Baixo	Regular
17	Fraco	Moderado	Alcalino	Médio	Ruim
18	Fraco	Moderado	Alcalino	Alto	Ruim
19	Fraco	Escuro	Ácido	Baixo	Ruim
20	Fraco	Escuro	Ácido	Médio	Ruim
21	Fraco	Escuro	Ácido	Alto	Ruim
22	Fraco	Escuro	Neutro	Baixo	Ruim
23	Fraco	Escuro	Neutro	Médio	Ruim
24	Fraco	Escuro	Neutro	Alto	Ruim
25	Fraco	Escuro	Alcalino	Baixo	Ruim
26	Fraco	Escuro	Alcalino	Médio	Ruim
27	Fraco	Escuro	Alcalino	Alto	Péssima
28	Médio	Claro	Ácido	Baixo	Ruim
29	Médio	Claro	Ácido	Médio	Ruim
30	Médio	Claro	Ácido	Alto	Ruim
31	Médio	Claro	Neutro	Baixo	Boa
32	Médio	Claro	Neutro	Médio	Boa


Regras inseridas no modelo <i>Fuzzy</i> (AND)					
Combinação das variáveis: Condutividade, Cor, pH e Turbidez					
Regra	Se	Se	Se	Se	Então
	Condutividade	Cor	pH	Turbidez	Definição
33	Médio	Claro	Neutro	Alto	Ruim
34	Médio	Claro	Alcalino	Baixo	Ruim
35	Médio	Claro	Alcalino	Médio	Ruim
36	Médio	Claro	Alcalino	Alto	Ruim
37	Médio	Moderado	Ácido	Baixo	Ruim
38	Médio	Moderado	Ácido	Médio	Regular
39	Médio	Moderado	Ácido	Alto	Ruim
40	Médio	Moderado	Neutro	Baixo	Ruim
41	Médio	Moderado	Neutro	Médio	Regular
42	Médio	Moderado	Neutro	Alto	Ruim
43	Médio	Moderado	Alcalino	Baixo	Ruim
44	Médio	Moderado	Alcalino	Médio	Regular
45	Médio	Moderado	Alcalino	Alto	Ruim
46	Médio	Escuro	Ácido	Baixo	Ruim
47	Médio	Escuro	Ácido	Médio	Ruim
48	Médio	Escuro	Ácido	Alto	Ruim
49	Médio	Escuro	Neutro	Baixo	Ruim
50	Médio	Escuro	Neutro	Médio	Ruim
51	Médio	Escuro	Neutro	Alto	Ruim
52	Médio	Escuro	Alcalino	Baixo	Ruim
53	Médio	Escuro	Alcalino	Médio	Ruim
54	Médio	Escuro	Alcalino	Alto	Ruim
55	Forte	Claro	Ácido	Baixo	Ruim
56	Forte	Claro	Ácido	Médio	Ruim
57	Forte	Claro	Ácido	Alto	Ruim
58	Forte	Claro	Neutro	Baixo	Regular
59	Forte	Claro	Neutro	Médio	Ruim
60	Forte	Claro	Neutro	Alto	Péssima
61	Forte	Claro	Alcalino	Baixo	Ruim
62	Forte	Claro	Alcalino	Médio	Ruim
63	Forte	Claro	Alcalino	Alto	Péssima
64	Forte	Moderado	Ácido	Baixo	Péssima
65	Forte	Moderado	Ácido	Médio	Péssima

Regras inseridas no modelo <i>Fuzzy</i> (AND)					
Combinação das variáveis: Condutividade, Cor, pH e Turbidez					
Regra	Se	Se	Se	Se	Então
	Condutividade	Cor	pH	Turbidez	Definição
66	Forte		Ácido	Alto	Péssima
67	Forte	Moderado	Neutro	Baixo	Péssima
68	Forte	Moderado	Neutro	Médio	Péssima
69	Forte	Moderado	Neutro	Alto	Péssima
70	Forte	Moderado	Alcalino	Baixo	Péssima
71	Forte	Moderado	Alcalino	Médio	Péssima
72	Forte	Moderado	Alcalino	Alto	Péssima
73	Forte	Escuro	Ácido	Baixo	Péssima
74	Forte	Escuro	Ácido	Médio	Péssima
75	Forte	Escuro	Ácido	Alto	Péssima
76	Forte	Escuro	Neutro	Baixo	Ruim
77	Forte	Escuro	Neutro	Médio	Ruim
78	Forte	Escuro	Neutro	Alto	Ruim
79	Forte	Escuro	Alcalino	Baixo	Péssima
80	Forte	Escuro	Alcalino	Médio	Péssima
81	Forte	Escuro	Alcalino	Alto	Péssima

Fonte: Autora, 2025.

A etapa seguinte consistiu na construção do diagrama em blocos, apresentado na Figura 9, no qual a lógica *fuzzy* é implementada para realizar a análise dos dados. Esse diagrama representa a estrutura funcional do sistema, evidenciando o fluxo de informações entre os parâmetros de entrada e o processo de inferência que resulta na classificação da qualidade da água.

Figura 9 - Digrma em blocos do controlador.



Fonte: Autora, 2025.

Foram incorporados quatro blocos de entrada, cada um representando os parâmetros medidos: condutividade, cor, *pH* e turbidez, respectivamente. As saídas desses blocos de entrada foram conectadas a um multiplexador (Mux), que será responsável por enviar os quatro valores dos parâmetros ao bloco *fuzzy*, onde foram inseridas todas as funções de pertinência e regras do modelo. Foi adicionado um bloco de operador relacional à saída do modelo *fuzzy*, encarregado de comparar os valores com o bloco denominado “*setpoint_qualidade*”. A lógica implementada é simples: se o valor da saída *fuzzy* for inferior a 71, a água não está pronta para o consumo. Por outro lado, se o valor for superior a 71, significa que a água está boa para o consumo. Com base nessa regra, é acionada uma lâmpada indicadora — verde para sinalizar água em condições seguras e vermelha para água inadequada para consumo. Além disso, foi inserido um bloco de exibição (*display*) para apresentar o valor calculado pelo modelo *fuzzy* e outro bloco (“*to workspace*”) que registra a saída do comparador.

RESULTADOS

Após o desenvolvimento do modelo *fuzzy*, conforme descrito acima, foram realizados testes para sua validação. Para isso, analisaram-se 25 amostras de água retiradas de um banco de dados particular, nas quais os quatro parâmetros de entrada foram inseridos no modelo. Este, por sua vez, gerou um valor que foi comparado com o Índice de Qualidade da Água (IQA), cujo *qi* varia de 0 a 100,

sendo 100 = muito bom, 70 = bom, 50 = regular e 30 = ruim. Dessa forma, foi possível avaliar se a água era adequada para o consumo. O objetivo principal é que o modelo *fuzzy* alcance uma taxa de concordância superior a 97% em relação às classificações obtidas pelo IQA clássico, demonstrando sua eficácia como ferramenta alternativa de avaliação da qualidade da água.

Tabela 3 - Amostras para a Análise.

<i>Fuzzy</i>						<i>IQA</i>					
Amostras	Condutividade (μS/cm)	Cor (uH)	pH	Turbidez (NTU)	Valor Final com o Fuzzy	Condutividade (μS/cm)	Cor (uH)	pH	Turbidez (NTU)	Valor final com IQA	Qualidade da Água (IQA)
1	300	45	7.0	0.5	72,3	100	50	100	100	75.79	Boa
2	1600	4	5.9	8.5	56,5	30	100	50	50	53.78	Regular
3	320	50	7.4	0.6	67,8	100	30	100	100	61.78	Regular
4	1400	42	7.3	6.8	54,3	50	50	100	50	54.34	Regular
5	280	55	7.0	0.8	68,8	100	30	100	100	61.78	Regular
6	1650	3	7.6	8.7	54,1	30	100	100	50	58.45	Regular
7	260	36	7.1	10.9	70,7	100	50	100	30	68.83	Regular
8	1500	52	4.9	0.9	42,2	50	30	30	100	40.52	Ruim
9	285	47	7.0	1.0	70	100	30	100	70	60.04	Regular
10	1900	50	6.5	11.8	49,9	30	30	100	30	34.66	Ruim
11	1600	44	9.3	8.3	39,8	30	50	50	50	40.76	Ruim
12	300	5	7.5	0.7	94	100	100	100	100	100.00	Ótima
13	1850	6	4.7	9.8	48,8	30	70	30	50	43.86	Ruim
14	290	4	7.1	0.9	94,3	100	100	100	100	100.00	Ótima
15	1550	37	5.9	6.5	47,3	30	50	50	50	40.76	Ruim
16	1650	5	6.8	8.2	56,2	30	100	100	50	58.45	Regular
17	305	54	7.4	0.8	68,2	100	30	100	100	61.78	Regular
18	295	4	7.2	0.5	93,7	100	100	100	100	100.00	Ótima
19	1750	45	4.9	7.6	39	30	50	30	50	38.34	Ruim
20	275	53	7.5	0.6	70,9	100	30	100	100	61.78	Regular
21	1600	50	9.1	8.9	39	30	30	50	50	33.23	Ruim
22	310	3	7.3	1.0	91,8	100	100	100	70	97.19	Ótima
23	1850	6	9.2	7.4	39,5	30	70	50	50	46.63	Ruim
24	270	3	7.2	0.9	94,3	100	100	100	100	100.00	Ótima
25	1600	5	7.5	9.3	55,4	30	100	100	50	58.45	Regular

Fonte: Autora, 2025.

Conforme apresentado na Tabela 3, com base na análise das 25 amostras de água avaliadas pelo modelo *fuzzy*, observou-se que 8 amostras (32%) foram classificadas como de qualidade ruim, indicando condições inadequadas para consumo humano. Em contrapartida, apenas 6 amostras (24%) apresentaram qualidade satisfatória, sendo 1 amostra (4%) classificada como boa e 5 amostras (20%) como ótimas, e 11 amostras (44%) obtiveram classificação regular, situando-se em uma condição intermediária de qualidade. Esses resultados evidenciam uma predominância de amostras com qualidade abaixo dos padrões recomendados, o que reforça a importância da aplicação do modelo *fuzzy* para a detecção e classificação de níveis críticos de qualidade da água, permitindo identificar parâmetros que necessitam de maior atenção e possíveis intervenções para garantir a potabilidade. Além disso, a análise possibilitou identificar tendências importantes, evidenciando a influência de parâmetros críticos nas classificações negativas. Observou-se, que a turbidez apresentou valores acima dos limites aceitáveis na maior parte das amostras classificadas como ruins e foram investigadas possíveis correlações entre variáveis, como condutividade e *pH*, que podem estar diretamente associadas à deterioração da qualidade da água. Para alcançar uma análise mais precisa, foram realizados diversos ajustes finos nas funções de pertinência de entrada, saída e em suas regras, permitindo que o controlador avaliasse os dados de forma mais eficiente e confiável.

CONCLUSÃO

A metodologia proposta se comportou de forma adequada, como esperado este modelo nos forneceu uma análise final da qualidade da água.

A lógica *fuzzy* demonstrou ser eficaz ao fornecer, a avaliação da qualidade da água, indicando se as amostras analisadas eram ou não adequadas para o consumo. Sistemas complexos, não lineares e intermitentes, com parâmetros variantes no tempo e sujeitos a incertezas inerentes, frequentemente apresentam desafios para modelos matemáticos tradicionais. Nesse contexto, abordagens baseadas em técnicas de inteligência artificial, como a lógica *fuzzy*, representam uma alternativa. O modelo *fuzzy* se destaca por sua capacidade de lidar com dados imprecisos, ambíguos ou incompletos, tornando-se especialmente útil em aplicações práticas onde a formulação matemática exata é complexa. Além

disso, permite a incorporação de conhecimento especializado por meio de variáveis linguísticas, possibilitando maior adaptabilidade às condições dinâmicas do sistema. Como resultado, os modelos *fuzzy* proporcionam soluções mais robustas e interpretáveis, favorecendo a tomada de decisão e oferecendo uma representação realista dos fenômenos analisados.

A integração dessa abordagem com sistemas de monitoramento em tempo real pode expandir seu impacto, possibilitando uma gestão mais eficiente e econômica. Este modelo apresenta vantagens significativas, como o baixo custo de implementação, especialmente quando comparado a métodos tradicionais que exigem equipamentos complexos ou análises laboratoriais demoradas. Sua estrutura modular e flexível facilita a integração com sistemas existentes e permite sua adaptação para diferentes escalas e condições ambientais.

O modelo *fuzzy* obteve uma taxa de acerto de 98% ao classificar a qualidade da água nessas 25 amostras. Dentre as amostras analisadas, 6 apresentaram qualidade considerada ideal para o consumo humano. As demais amostras foram classificadas como de qualidade regular ou ruim. Apesar desses resultados, é importante destacar que a água com qualidade inferior ainda pode ser reaproveitada.

Para evitar o desperdício de água, é possível realizar uma análise criteriosa para identificar oportunidades de reutilização da água considerada imprópria para consumo humano. O reaproveitamento pode ser realizado de diversas maneiras, especialmente em situações em que o acesso à água potável é limitado. Essas alternativas de uso contribuem para a sustentabilidade e a conservação dos recursos hídricos.

Aprimoramentos no modelo poderão ampliar sua aplicabilidade para contextos mais abrangentes e desafiadores, incluindo a integração com sensores inteligentes e sistemas baseados em Internet das Coisas (IoT). Essas tecnologias possuem o potencial de aprimorar significativamente a capacidade de monitoramento contínuo e preditivo da qualidade da água, fortalecendo a segurança hídrica em âmbito global e promovendo práticas mais sustentáveis na gestão dos recursos hídricos.

REFERÊNCIAS

- AMENDOLA, M.; SOUZA, A. L.; BARROS, L. C.** Manual do uso da teoria dos conjuntos fuzzy no MATLAB 6.5. Campinas: FEAGRI & IMECC/UNICAMP, 2005. 44 p.
- BARROS, L. C. de; BASSANEZI, R. C.** Tópicos de lógica fuzzy e biomatemática. Campinas: Unicamp, 2006. 382 p. (Coleção IMECC. Textos didáticos, v.5).
- BRASIL.** Ministério do Meio Ambiente. Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio). Ciranda das águas. Brasília, 2011. Disponível em: <http://www.icmbio.gov.br/educacaoambiental/images/stories/biblioteca/rio_20/Ciranda_das_Aguas.pdf>. Acesso em: 10 out. 2024.
- CHEN, C.; WAGNER, C.; GARIBALDI, J. M.** Gradient-based fuzzy system optimisation via automatic differentiation – FuzzyR as a use case. 2024. Disponível em: <<https://arxiv.org/abs/2403.12308>>. Acesso em: 20 jan. 2025.
- CORDON, O. et al.** Genetic fuzzy systems: evolutionary tuning and learning of fuzzy knowledge bases. Singapore: World Scientific, 2001.
- DE GODOY, F. O. et al.** Utilização da lógica fuzzy aplicada à energia solar. Cadernos de Ciência & Tecnologia, Brasília, v. 37, n. 2, p. 26663, 2020. Disponível em: <<http://file:///C:/Users/cso6482/Downloads/26663-127622-1-PB.pdf>>. Acesso em: 11 out. 2024.
- GARCIA, C. A. B.** Avaliação da qualidade da água utilizando a teoria fuzzy. Scientia Plena, Aracaju, v. 8, n. 7, 2012. Disponível em: <https://www.scientiaplena.org.br/sp/article/view/1024>. Acesso em: 17 de dezembro 2024.
- GOMIDE, F. A. C.; GUDWIN, R. R.** Modelagem, controle, sistemas e lógica fuzzy. SBA: Controle & Automação, Campinas, v. 4, n. 3, p. 97–115, set./out. 1994.
- KUMAR, M. S. et al.** Groundwater quality assessment for drinking, irrigation purposes and fuzzy logic-based water quality index for industrial suitability in Walajapet Taluk, Ranipet District, Tamil Nadu, India. AQUA – Water Infrastructure, Ecosystems and Society, [S. l.], v. 73, n. 8, p. 1766–1785, 2024. DOI: <https://doi.org/10.2166/aqua.2024.020>. Disponível em: <https://iwaponline.com/aqua/article/73/8/1766/103991>. Acesso em: 25 maio 2025.
- MANDANI, E. H.** Application of fuzzy algorithms for control of simple dynamic plant. Proceedings of the Institution of Electrical Engineers, London, v. 121, n. 12, p. 1585–1588, 1974.
- MERLI, R. F.; ALMEIDA, L. M. W. de.** Nem tudo é tão certo como parece ser: a matemática fuzzy como linguagem. 2011. 13 f. Dissertação (Filosofia da Educação Matemática) – Universidade Estadual de Londrina, Londrina, PR, 2011.
- MISHRA, A.; PANIGRAHI, C. K.; PANDA, B. S.** Advancing aquaculture: fuzzy logic-based water quality monitoring and maintenance system for precision aquaculture. Aquaculture International, [S. l.], v. 32, p. 215–236, 2024. DOI: <https://doi.org/10.1007/s10499-024-01701-2>. Disponível em: <https://link.springer.com/article/10.1007/s10499-024-01701-2>. Acesso em: 25 maio 2025.
- NARS; BRUEN.** A GIS-based water quality model using fuzzy logic. 2003. (Referência incompleta – incluir autores completos e dados do periódico ou evento).
- OCAMPO-DUQUE, W.; FERNÁNDEZ, N.; MADERA, C. A.** Water quality index improvement using fuzzy logic: a case study. Environmental Monitoring and Assessment, v. 124, p. 229–241, 2007. DOI: <https://doi.org/10.1007/s10661-006-9221-1>.

PASCHOAL, R. S. Usos da água e necessidades de tratamento para consumo humano. 2012. 52 f. Trabalho de Conclusão de Curso.

QUALIDADE da água: parâmetros e padrões. Revista *Tratamento de Água*, São Paulo, 2015. Disponível em: <https://tratamentodeagua.com.br/artigo/qualidade-da-agua/>. Acesso em: 20 janeiro 2025.

SILVA, R. A. C. Inteligência artificial aplicada a ambientes de engenharia de software: uma visão geral. Viçosa: Universidade Federal de Viçosa, 2005.

TOLEDO, O. M.; COSENZA, C. A. N. Metodologia de avaliação de desempenho baseada em lógica fuzzy. In: CONGRESSO BRASILEIRO DE ENSINO DE ENGENHARIA – COBENGE, 32., 2004, Brasília. Anais [...]. Brasília: ABENGE, 2004.

VÁSQUEZ, J. L. M. et al. Water treatment plant prototype with pH control modeled on fuzzy logic for removing arsenic using Fe(VI) and Fe(III). *Water*, [S. l.], v. 12, n. 10, p. 2834, 2020. DOI: <https://doi.org/10.3390/w12102834>. Disponível em: <https://www.mdpi.com/2073-4441/12/10/2834>. Acesso em: 7 maio 2025.

VIDAL. Aplicação fuzzy x PID – técnicas de controle em ambientes simulados. São Paulo: Editora Annris, 2015.

ZADEH, L. A. Fuzzy logic, neural networks, and soft computing. *Communications of the ACM*, v. 37, n. 3, p. 77–84, 1994.

ZANETTI, W. A. L.; MOLLO NETO, M. Construção de algoritmo fuzzy para rastreamento solar com painel fotovoltaico montado em suporte de um eixo. *Enciclopédia Biosfera*, v. 13, p. 1643–1654, 2016. DOI: https://doi.org/10.18677/EnciBio_2016B_15.

REVISÃO E COMPARAÇÃO DE ESTRATÉGIAS DE CONTROLE - CONTROLE CLÁSSICO, MODERNO, ADAPTATIVO, NÃOLINEAR E INTELIGENTE

Wesley Rossi Pimenta
Instituto Federal do Rio de Janeiro (IFRJ)

Leonardo de Carvalho Vidal
Instituto Federal do Rio de Janeiro (IFRJ)

RESUMO

Este artigo apresenta uma revisão abrangente das principais estratégias de controle utilizadas no âmbito da automação industrial, robótica e sistemas energéticos, com foco no período de 2022-2025. O objetivo é comparar os métodos clássicos (PID, técnicas de domínio da frequência como diagrama de Bode e lugar das raízes), modernos (representação em espaço de estados, LQR e observadores), adaptativos (controle L1, MRAC e escalonamento de ganhos), não-lineares (controle por modo deslizante e *backstepping*) e inteligentes (lógica *fuzzy*, redes neurais, controle *neurofuzzy* e aprendizado por reforço). Para cada categoria são discutidos fundamentos, formulações matemáticas e casos de aplicação recentes, destacando vantagens, limitações e tendências de pesquisa. A revisão evidencia que, embora o controle clássico permaneça amplamente utilizado devido à simplicidade, as crescentes exigências de desempenho e robustez, aliadas à presença de incertezas e sistemas altamente não-lineares, motivam o uso de técnicas modernas, adaptativas e inteligentes. Métodos como LQR com observador de Kalman têm demonstrado melhor tempo de acomodação em aplicações veiculares, enquanto estratégias adaptativas como o controle L1 melhoram o desempenho de helicópteros de pequeno porte sob incertezas. Técnicas inteligentes, incluindo controladores *fuzzy*, *neurofuzzy* e aprendizado por reforço, permitem automação e autoajuste em situações onde o modelo é impreciso. Conclui-se que a integração de abordagens híbridas, combinando métodos clássicos e modernos com algoritmos de aprendizado, é promissora para sistemas ciberfísicos e a Indústria 4.0.

Palavras-chave: Controle adaptativo; controle não-linear; controle inteligente.

INTRODUÇÃO

A engenharia de controle desempenha papel fundamental na automação de processos industriais, robótica, sistemas energéticos e veículos autônomos. Desde a Segunda Guerra Mundial, quando foram introduziram técnicas de domínio da frequência e lugar das raízes, o campo evoluiu de métodos lineares convencionais para abordagens baseadas em espaço de estados, controle robusto, técnicas adaptativas e, mais recentemente, algoritmos inteligentes. A literatura recente destaca que os controladores PID ainda dominam a indústria devido à simplicidade e ao bom compromisso entre desempenho e custo, sendo utilizados em mais de 90 % das aplicações (Ding *et al.*, 2023). Entretanto, o aumento da complexidade dos sistemas, a necessidade de lidar com incertezas e perturbações e o surgimento de sistemas ciberfísicos exigem estratégias de controle mais sofisticadas. Estudos sobre robôs autoequilibrados de duas rodas salientam que estes sistemas são subatuados e fortemente não lineares, sendo utilizados como plataformas de teste para comparar técnicas clássicas (PID e LQR), métodos não lineares (modo deslizante e MPC) e técnicas inteligentes (lógica *fuzzy*, redes neurais e aprendizado por reforço) (Zhang; Mohamad Nor, 2025).

A evolução histórica das estratégias de controle pode ser dividida em cinco grandes categorias: (i) controle clássico, baseado na análise de transferência e técnicas do domínio da frequência; (ii) controle moderno, centrado na representação em espaço de estados e em métodos de otimização como LQR; (iii) controle adaptativo, que ajusta parâmetros em tempo real para lidar com incertezas ou variações no processo; (iv) controle não linear, que explora propriedades estruturais de sistemas não lineares por meio de métodos como modo deslizante e *backstepping*; e (v) controle inteligente, que emprega lógica *fuzzy*, redes neurais artificiais (RNAs), sistemas *neurofuzzy* e aprendizado por reforço (RL) para automatizar a síntese de controladores. Cada abordagem possui fundamentos teóricos, equações características e campos de aplicação distintos, sendo que as técnicas modernas e inteligentes surgem como resposta às limitações dos métodos clássicos em sistemas complexos.

Apesar da popularidade dos controladores PID, a literatura recente evidencia diversas limitações quando eles são aplicados a sistemas de elevada ordem, com não linearidades, atrasos de transporte ou incertezas paramétricas. O método

de sintonização de ZieglerNichols, por exemplo, foi desenvolvido para plantas lineares e oferece apenas margens de estabilidade aproximadas; pequenas variações nos parâmetros podem gerar perdas significativas de desempenho (Ding *et al.*, 2023). Na abordagem de síntese direta, a sintonização baseia-se em modelos de primeira ou segunda ordem com atraso (FOPDT/SOPDT); entretanto, a aproximação de Taylor ou de Padé pode introduzir erros na representação da dinâmica, e métodos heurísticos, como nomogramas, produzem apenas soluções aproximadas (Kula, 2024). Pesquisas envolvendo de controle digital de sistemas massaamortecedor demonstra que a inclusão de um controlador PID digital, projetado pelo lugar das raízes, reduz o *overshoot* a zero e melhora o tempo de resposta (Al-Baidhani; Kazimierczuk, 2024), mas a sintonização ainda requer conhecimento especializado.

Em sistemas veiculares conectados por rede, atrasos de comunicação e perturbações ambientais desafiam o desempenho de controladores clássicos. A revisão de estratégias de controle para robôs autoequilibrados destaca que métodos lineares convencionais não são suficientes para lidar com a forte não linearidade e a subatuação dos sistemas, motivando a adoção de modos deslizantes, MPC e técnicas inteligentes como redes neurais e RL (Zhang; Mohamad Nor, 2025). Para veículos autônomos em pelotão, controladores LQR com observador de Kalman mantêm distâncias constantes sob ruído e atrasos, superando a resposta de PIDs convencionais (Murugan; Mohamed Ismail, 2025). Em helicópteros de pequeno porte, controladores L1 adaptativos enfrentam incertezas e perturbações estruturais mais eficientemente que PIDs ou SMCs (Bertolani *et al.*, 2024). Esses exemplos ilustram a necessidade de métodos robustos e adaptativos, capazes de atender requisitos de desempenho em ambientes imprevisíveis.

Outra problemática reside na falta de sistematização em técnicas de lógica *fuzzy*. Embora amplamente utilizadas para lidar com não linearidades, os controladores *fuzzy* exigem definições de regras baseadas em conhecimento de especialistas e sintonização manual. A revisão de controladores *fuzzy* para manipuladores robóticos de 3 graus de liberdade observa que a ausência de metodologia sistemática de projeto limita seu uso; pesquisadores combinam lógica *fuzzy* com redes neurais (ANFIS) para automatizar o ajuste de parâmetros (Kern; Marrero; Urrea, 2023). De modo semelhante, algoritmos de aprendizado

por reforço têm sido explorados para sintonização automática de controladores, porém a ausência de estruturas hierárquicas em métodos de autodisparo dificulta a aprendizagem e aumenta o custo computacional (Chen; Wan; Luan; Liu, 2024). Assim, a problemática central desta revisão é compreender como cada estratégia de controle aborda essas limitações e qual sua relevância para sistemas complexos atuais.

O presente trabalho tem como objetivo revisar, comparar e analisar criticamente as estratégias de controle clássico, moderno, adaptativo, não linear e inteligente, focando em publicações de 2022 a 2025. Buscase identificar fundamentos matemáticos, critérios de projeto, vantagens, desvantagens e campos de aplicação de cada método, bem como discutir tendências futuras e desafios. A partir dessa revisão, pretendese elaborar tabelas comparativas quanto à complexidade de implementação, custo computacional e desempenho, fornecendo ao leitor um panorama atual do estado da arte e orientações para escolha de técnicas apropriadas.

MATERIAIS E MÉTODOS

A estratégia de pesquisa bibliográfica adotada considerou artigos científicos publicados entre 2022 e 2025 em bases de dados reconhecidas e outras plataformas de acesso aberto. As palavras-chave utilizadas incluíram controle clássico, *PID*, *root locus*, *Bode*, *statespace*, *LQR*, *Kalman observer*, *adaptive control*, *L1*, *MRAC*, *gain scheduling*, *sliding mode*, *backstepping*, *fuzzy control*, *neural networks*, *ANFIS*, *reinforcement learning* e *intelligent control*. Foram selecionados artigos que apresentavam descrições claras das técnicas, formulação matemática, estudos de caso ou comparações de desempenho. Os critérios de exclusão envolveram trabalhos que não se enquadravam no período considerado, artigos que não apresentavam aplicações ou detalhes metodológicos e textos meramente introdutórios sem resultados empíricos.

Controle Clássico

O controle clássico baseia-se na representação em domínio da frequência e em funções de transferência. Os métodos de análise incluem o lugar das

raízes, diagramas de Bode e Nyquist, bem como a técnica de Routh–Hurwitz para estabilidade. A literatura recente reforça que os controladores PID continuam sendo a estratégia mais empregada na indústria, graças à facilidade de implementação e à estrutura simples de três termos (proporcional, integral e derivativo) (Ding *et al.*, 2023). Ainda assim, a sintonização adequada é essencial para garantir que o controlador atenda aos requisitos de velocidade de resposta e estabilidade. Já o método do lugar das raízes é utilizado para ajustar os ganhos de forma a deslocar os polos da malha fechada para regiões desejadas no plano complexo, melhorando a estabilidade e o tempo de resposta (Al-Baidhani; Kazimierczuk, 2024).

Outra tendência observada na literatura é a aplicação de técnicas de síntese direta para PI/PID em sistemas com atraso. Um estudo recente propôs sintonizar controladores para plantas inerciais com atraso baseando-se em modelos FOPDT e SOPDT, com o objetivo de atingir resposta sem oscilações no menor tempo possível (Kula, 2024). Ao empregar análise de lugar das raízes e evitar aproximações de alta ordem, o método permite calcular precisamente as configurações do controlador e superar limitações associadas a atrasos. O artigo revisa métodos clássicos como Ziegler–Nichols, CHR e o uso de nomogramas, salientando que são aproximados e sensíveis a variações (Kula, 2024).

A dinâmica de um sistema linear invariante no tempo é tradicionalmente descrita por sua função de transferência $G(s)$, relacionando a saída $Y(s)$ à entrada $U(s)$. O controlador PID possui a função de transferência $G_c(s) = K_p + \frac{K_i}{s} + K_d s$ onde K_p , K_i , K_d são os ganhos proporcional, integral e derivativo, respectivamente. Quando o PID está em malha fechada com a planta, a função de transferência de malha fechada é representada conforme Equação 1.

$$G_{cl}(s) = \frac{G_p(s) G_c(s)}{1 + G_p(s) G_c(s)} \quad (1)$$

O projeto pelo lugar das raízes consiste em traçar a trajetória dos polos de $G_{cl}(s)$ à medida que o ganho varia, escolhendo valores que posicionem os polos em regiões que satisfaçam requisitos de amortecimento e frequência natural.

O estudo do controle digital para sistemas massaamortecedor serviu como um caso didático para a aplicação do lugar das raízes na sintonia

de PIDs. A análise revelou que o sistema não compensado apresenta instabilidade marginal; após a inclusão do PID digital, o *overshoot* foi eliminado e o tempo de acomodação reduzido (Al-Baidhani; Kazimierczuk, 2024). Outro exemplo envolve a sintonização de controladores PI/PID para plantas com atraso usando síntese direta. Os autores demonstraram que o método consegue produzir respostas sem oscilações e tempo de estabelecimento mínimo, superando limitações de métodos heurísticos e de aproximação (Kula, 2024). Adicionalmente, controladores fracionários $PI^{\alpha}D^{\mu}$ foram propostos para sistemas de suspensão ativa, explorando cálculo fracionário para melhorar resposta transitória e rejeição de perturbações; contudo, poucos trabalhos recentes abordam aplicações práticas amplas, indicando uma lacuna na literatura.

Controle Moderno

O controle moderno surgiu como alternativa às limitações do domínio da frequência, permitindo o tratamento de sistemas multivariáveis e a consideração de estados internos. A representação em espaço de estados descreve a dinâmica por meio das matrizes de estado A , entrada B , saída C e transmissão direta D . Essa forma fornece uma base para técnicas de realimentação de estados, observadores e controladores ótimos. Conforme destacado em um estudo de modelagem dinâmica, a representação em espaço de estados permite analisar estabilidade, resposta transitória e estacionária, além de facilitar o projeto de controladores de realimentação de estados e de observadores (Barrios Sánchez; Baeza Serrato, 2023).

No espaço de estados, a equação de estado é dada conforme representado pela Equação 2:

$$\dot{x}(t) = A x(t) + B u(t); \quad y(t) = C x(t) + D u(t) \quad (2)$$

Onde $x(t) \in \mathbb{R}^n$ é o vetor de estados, $u(t) \in \mathbb{R}^m$ o vetor de entradas, $y(t) \in \mathbb{R}^p$ o vetor de saídas, $A \in \mathbb{R}^{n \times n}$ a matriz do sistema, $B \in \mathbb{R}^{n \times m}$ a matriz de controle, $C \in \mathbb{R}^{p \times n}$ a matriz de saída e $D \in \mathbb{R}^{p \times m}$ a matriz de transmissão direta (Barrios Sánchez; Baeza Serrato, 2023). A função de transferência matricial é obtida por $G(s) = C(sI - A)^{-1}B + D$. O projeto de realimentação de estados define

$u(t) = -Kx(t)$, onde K é calculado pelo método de Ackermann ou por solução de Riccati. O observador de Kalman estima $\hat{x}$ a partir de medições ruidosas, solucionando uma equação de Riccati dual para determinar a matriz do observador L . A implementação do CKOLQR (observador de Kalman coordenado e LQR) consiste em usar para realimentação e para estimativa de estados, formando um sistema de compensação dinâmico (Barrios Sánchez; Baeza Serrato, 2023).

Entre as técnicas modernas, destacase o regulador quadrático linear (LQR), que busca minimizar um funcional de custo quadrático $J = \int_0^\infty [x(t)^T Q x(t) + u(t)^T R u(t)] dt$ sujeito à dinâmica de estado. A solução envolve calcular uma matriz de ganho via equação algébrica de Riccati, permitindo realimentação de estados $u(t) = -Kx(t)$. Observadores de Kalman são frequentemente combinados com LQR para estimar estados não mensuráveis e rejeitar ruído (Murugan; Mohamed Ismail, 2025).

O método CKOLQR foi aplicado ao controle de pelotões de veículos autônomos. O estudo evidencia que a combinação do LQR com observador de Kalman mantém a distância entre veículos sob ruídos, atrasos e perturbações, apresentando melhor desempenho que PIDs em termos de tempo de acomodação e robustez (Murugan; Mohamed Ismail, 2025). Em biomecatrônica, um controlador LQR sintonizado por algoritmo de otimização lobo cinzento (IGWO) foi proposto para mãos protéticas multifuncionais. O IGWOLQR alcançou tempos de acomodação de 0,018 s com zero *overshoot*, superando controladores PID e PIDPSO (Ahmed; Aly; Elhabib, 2025). Outro trabalho utilizou métodos de gradiente para otimizar matrizes de ponderação do LQR, mostrando que abordagens bioinspiradas e tentativa-erro podem ser substituídas por soluções analíticas de baixo custo computacional (Choi; Kim; Turner, 2023). Além disso, a representação em espaço de estados foi empregada para derivar modelos de sistemas de simulação, permitindo o uso da fórmula de Ackermann para posicionar polos e projetar controladores (Barrios Sánchez; Baeza Serrato, 2023).

Controle Adaptativo

Controladores adaptativos ajustam automaticamente seus parâmetros para lidar com variações dinâmicas ou incertezas. As abordagens incluem o controle adaptativo de referência de modelo (MRAC), controle L1, ganho

programável (*gain scheduling*) e técnicas baseadas em autoajuste (Bertolani *et al.*, 2024). O MRAC convencional, por sua vez, pode sofrer com ganhos elevados que induzem oscilações. Controladores adaptativos baseados em estratégias de escalonamento de ganhos também são utilizados em robôs móveis, onde parâmetros são ajustados em função do ponto de operação, e comparados a controladores *fuzzy* multimodelo (Miquelanti *et al.*, 2024).

Além disso, o aprendizado por reforço tem sido investigado como ferramenta de ajuste adaptativo de controladores. Um método de *tuning* multifase baseado em *Deep Deterministic Policy Gradient* (DDPG) foi proposto para sintonizar automaticamente parâmetros de PID. Outra abordagem considera o controle autodisparado em sistemas de motores em rede, onde um método hierárquico de aprendizado por reforço (HRL) divide a política em camadas superior e inferior, reduzindo o espaço de exploração e melhorando a eficiência de aprendizagem (Chen; Wan; Luan; Liu, 2024).

No MRAC clássico, define-se um modelo de referência com dinâmica desejada e estrutura de controladora ajustável. A lei de adaptação é derivada com base em critérios de Lyapunov para garantir estabilidade. Por exemplo, considerando um sistema de primeira ordem $\dot{x} = Ax + Bu$ e um modelo de referência $\dot{x} = a_m x_m + b_m r$, a lei de controle adaptativo é $u = \hat{\theta}_1 x + \hat{\theta}_2 r$ com parâmetros $\hat{\theta}_i$ ajustados por $\dot{\theta} = -\zeta x e$, onde $e = x - x_m$. Já o controle L1 adaptativo incorpora um filtro de baixa frequência para separar rapidamente a adaptação da robustez. O controle L1 pode ser implementado no domínio da frequência ou em espaço de estados, sendo que a entrada de controle inclui componentes de previsão e de compensação de incertezas (Bertolani *et al.*, 2024).

Na estratégia de *gain scheduling*, o modelo do sistema é linearizado em diferentes pontos de operação e uma família de controladores lineares é interpolada conforme as variáveis de agendamento. Em sistemas robóticos de futebol, os controladores PI são sintonizados para modelos locais via resposta ao degrau; em seguida, um esquema de escalonamento ajusta os ganhos em tempo real para rastrear a velocidade das rodas, sendo comparado a um controlador *fuzzy* multimodelo (Miquelanti *et al.*, 2024).

Para o ajuste adaptativo via RL, a abordagem de DDPG define uma função de recompensa baseada no erro de rastreamento e na energia de controle; o agente aprende uma política determinística $\mu(s|\theta): S \rightarrow A$ que mapeia estados

para parâmetros de PID, e a atualização dos pesos é realizada pelo gradiente de política. No método HRL para controle autodisparado, a política superior decide instantes de acionamento e a política inferior gera sinais de controle, com treinamento baseado na função de custo acumulado; redes neurais recorrentes capturam dependências temporais e prétreinamento é utilizado para melhorar a convergência (Chen; Wan; Luan; Liu, 2024).

No controle de helicópteros de pequeno porte, o algoritmo L1 adaptativo foi utilizado para a autopilotagem de velocidade. Os autores afirmam que PIDs, *backstepping*, modo deslizante e MPC enfrentam problemas de *chattering*, sensibilidade a modelos e altas exigências computacionais, enquanto o L1 separa robustez e adaptação, permitindo rápida convergência sem oscilações (Bertolani *et al.*, 2024). Em veículos autônomos com quatro rodas independentes, uma estratégia hierárquica combinou *backstepping* adaptativo e modo deslizante dinâmico, mais um controlador *fuzzy* de relação de escorregamento, melhorando a precisão de rastreamento e robustez (Zhang; Chen; Yu, 2024)

Em robótica móvel, controladores de escalonamento de ganho foram implementados em robôs de futebol; os resultados mostraram que a estratégia permitiu rastrear a referência de velocidade com pequenos *overshoots*, e o desempenho foi comparável ao de controladores *fuzzy* multimodelo, demonstrando a eficácia de ambas as abordagens (Miquelanti *et al.*, 2024). No campo do RL, o método multifase de ajuste de PIDs reduziu erros de rastreamento em até 30 % em sistemas simulados (Ding *et al.*, 2023), enquanto o framework HRL para controle autodisparado de motores em rede melhorou a eficiência de aprendizagem ao dividir a política em camadas e utilizar redes neurais recorrentes (Chen; Wan; Luan; Liu, 2024).

Controle Nãolinear

Sistemas nãolineares apresentam dinâmicas complexas que não podem ser tratadas eficazmente por técnicas lineares. Entre as metodologias nãolineares mais estudadas estão o modo deslizante (SMC) e o *backstepping*. O SMC é uma técnica de estrutura variável que comuta o controle entre diferentes regimes para conduzir o estado do sistema até uma superfície de deslizamento, na qual a dinâmica reduzida se torna insensível a perturbações e incertezas (Latosiński;

Adamiak, 2024). A literatura relata que a seleção adequada da hipersuperfície de deslizamento é crucial para garantir estabilidade, resposta rápida e erro zero no regime permanente. Contudo, quando implementado em sistemas digitais, o SMC contínuo gera oscilações de alta frequência (fenômeno de *chattering*), levando ao desenvolvimento de versões discretas e métodos de *reaching law* para atenuar esse problema (Latosiński; Adamiak, 2024).

O *backstepping* é uma abordagem baseada em Lyapunov para sistemas não lineares estritamente retrocedentes, construída de forma recursiva: o projeto começa por uma subdinâmica de ordem inferior e, a cada etapa, adicionase uma lei de controle virtual até que a entrada real seja obtida. Um levantamento recente enfatiza que o *backstepping* permite design modular e pode ser estendido por técnicas robustas e adaptativas, bem como por funções barreira e redes neurais (Ren, 2023). Essa flexibilidade o torna aplicável a sistemas com restrições de estado, atrasos, não linearidades puras e perturbações estocásticas. Entretanto, para sistemas de alta ordem, o número de passos aumenta significativamente, podendo resultar em controladores complexos.

No SMC, define-se uma superfície de deslizamento $s(x, t)$ a lei de controle é composta por um termo de aproximação e um termo de deslizamento de alta frequência que força a trajetória para a superfície. Para um sistema de primeira ordem $\dot{x} = f(x) + g(x)u$, escolhe-se $s = cx$ (com constante $c > 0$), e define-se a lei de controle $u = -\frac{f(x)}{g(x)} - k \operatorname{sgn}(s)$, onde k é o ganho de deslizamento. Em sistemas discretos, substitui-se a derivada por diferenças, e leis de alcance definem como $s(k+1)$ evolui para zero, minimizando *chattering* (Latosiński; Adamiak, 2024).

No *backstepping*, para um sistema do tipo strictfeedback com equações $\dot{x}_1 = f_1(x_1) + g_1(x_1)x_2$ e $\dot{x}_2 = f_2(x_1, x_2) + g_2(x_1, x_2)u$, elegem-se funções de Lyapunov parciais e variáveis virtuais. O primeiro passo projeta uma lei virtual $\alpha(x_1)$ para estabilizar (x_1) no passo seguinte, define-se o erro $z_2 = x_2 - \alpha(x_1)$ e projetase o controle real u de modo que a derivada de Lyapunov seja negativa. O processo se repete para sistemas de ordem superior. A literatura recente destaca extensões que incorporam funções de Nussbaum, controladores de tempo finito, funções de barreira e integrações com redes neurais para compensar incertezas (Ren, 2023).

Os métodos de SMC têm sido aplicados em estruturas de energia e sistemas eletromecânicos. Um estudo de 2024 revisou estratégias de SMC

em tempo discreto, enfatizando que versões discretas reduzem o *chattering* e mantêm robustez a distúrbios, com baixo custo computacional (Latosiński; Adamiak, 2024). Em veículos autônomos, combinouse *backstepping* adaptativo e modo deslizante dinâmico com controle *fuzzy* para otimizar a velocidade e o deslizamento de rodas, melhorando a precisão de rastreamento e a robustez frente a incertezas (Sun *et al.*, 2024). Outro exemplo são robôs autoequilibrados de duas rodas, cuja revisão relata que métodos como SMC e *backstepping* são preferíveis devido à robustez e capacidade de lidar com a não linearidade, superando abordagens lineares e clássicas (Zhang; Mohamad Nor, 2025).

Controle Inteligente

O controle inteligente incorpora técnicas de inteligência artificial (IA) para lidar com sistemas altamente não lineares, incertos ou difíceis de modelar. Entre as abordagens mais comuns estão a lógica *fuzzy*, redes neurais artificiais (RNAs), sistemas *neurofuzzy* e o aprendizado por reforço (RL). Controladores *fuzzy* utilizam regras linguísticas para mapear entradas (erros e derivadas) a saídas, sendo adequados para sistemas que exigem conhecimento heurístico. No entanto, a falta de metodologia sistemática de projeto torna o ajuste de parâmetros demorado e dependente de especialistas (Kern; Marrero; Urrea, 2023). A incorporação de redes neurais permite automatizar o ajuste de parâmetros *fuzzy*, originando sistemas *neurofuzzy* como o ANFIS, que aprendem a relação entrada-saída a partir de dados e aumentam a precisão do controle (Kern; Marrero; Urrea, 2023).

Redes neurais puras podem ser utilizadas para modelagem de sistemas e para construir controladores com autoajuste. Ainda assim, modelos de aprendizado profundo são frequentemente considerados “caixas pretas”, dificultando a interpretação das leis de controle. Técnicas evolutivas como programação genética têm sido exploradas para projetar controladores que mantenham estrutura matemática explícita; um estudo revisa o uso de programação genética para sintetizar controladores no domínio do tempo, replicando controladores clássicos e integrando IA ao design de controle (García; Velasco; Angulo; Marti; Camacho, 2023).

O aprendizado por reforço (RL) tem ganhado destaque na sintonização de controladores. Métodos como o DDPG multifase para ajuste de PIDs impõem restrições de ação e utilizam arquitetura residual na rede ator para evitar gradiente nulo; os resultados mostram melhoria significativa no erro de rastreamento (Ding *et al.*, 2023). Em sistemas de controle em rede, um *framework* de RL hierárquico (HRL) para controle autodisparado foi proposto, dividindo a política em níveis superior e inferior e usando redes neurais recorrentes para capturar dependência temporal (Chen; Wan; Luan; Liu, 2024). Na área de telecomunicações, RL também tem sido aplicado para lidar com latência variável em sistemas 5G, permitindo ajustar protocolos de controle baseados em inferência temporal, conforme revisão sobre estratégias adaptativas em sistemas de rede (Gilerson; Bunte; Kehl; Schmitt, 2025). Essas abordagens evidenciam o potencial do RL em substituir algoritmos heurísticos e fornecer sintonização automática.

Em um controlador *fuzzy* Mamdani típico, define-se um conjunto de funções de pertinência para as variáveis de entrada (por exemplo, erro e derivada do erro) e um conjunto de regras do tipo “Se (erro é A) e (derivada é B), então (saída é C)”. A inferência *fuzzy* calcula a saída agregando as conclusões das regras e, posteriormente, aplica um processo de defuzzificação (média ponderada, centroide, etc.). No estudo sobre manipulação robótica de 3 graus de liberdade, o controlador *fuzzy* utiliza nove regras com entradas de erro e derivada e produz torque de controle; o sistema ANFIS, por sua vez, aprende o modelo dinâmico inverso, ajustando automaticamente parâmetros de pertinência e consequentes (Kern; Marrero; Urrea, 2023).

Redes neurais artificiais podem ser descritas por $y = f(Wx + b)$ onde W representa pesos sinápticos e f é uma função de ativação. O treinamento consiste em minimizar uma função de custo (como erro quadrático) via algoritmos de retropropagação. No contexto de controle, as RNAs podem aproximar a função de controle ou estimar dinâmicas não modeladas. Sistemas *neurofuzzy* combinam as regras *fuzzy* com a capacidade de aprendizado das RNAs: camadas de antecedente implementam funções de pertinência e camadas de consequente realizam regressão adaptativa.

No aprendizado por reforço, o problema é formulado como um processo de decisão de Markov; um agente observa o estado a_t e executa uma ação e recebe uma recompensa r_t . O objetivo é maximizar a soma de recompensas

descontadas. O DDPG utiliza redes neurais para parametrizar a política determinística $\mu(s|\theta)$ e a função de valor de ação $Q(s, a|w)$ a atualização ocorre via gradiente de política e do crítico. No método multifase de ajuste de PIDs, ações são restringidas para garantir estabilidade e a estrutura residual evita problemas de gradiente (Ding *et al.*, 2023). O framework HRL para autodisparo modela a política em dois níveis; redes neurais recorrentes são utilizadas para aproximar a função Q , e um estágio de prétreino fornece conhecimento prévio para acelerar a aprendizagem (Chen; Wan; Luan; Liu, 2024).

Na manipulação robótica, um controlador *fuzzy* e ANFIS foram aplicados a um manipulador de 3 graus de liberdade. O estudo constatou que ambos apresentaram alta precisão e baixo erro de referência; o ANFIS obteve melhor desempenho em termos de erro quadrático médio e ITAE devido à capacidade de aprender o modelo inverso (Kern; Marrero; Urrea, 2023). Os autores ressaltam que a escolha do método de controle e dos dados de treinamento é crítica, bem como o tempo de treinamento e a parametrização (Kern; Marrero; Urrea, 2023).

Em aplicações de RL, o método multifase para ajuste de PIDs obteve redução de 16 à 30 % no erro de rastreamento comparado a algoritmos convencionais (Ding *et al.*, 2023). Em sistemas de motores interconectados, o *framework* HRL dividiu a política de controle em dois níveis e utilizou redes neurais recorrentes para capturar dinâmica temporal; os autores mostraram que a abordagem reduz o espaço de exploração e melhora a eficiência de aprendizagem, permitindo prétreinamento que acelera a convergência (Chen; Wan; Luan; Liu, 2024). Controladores *fuzzy* multimodelo foram comparados a estratégias de escalonamento de ganhos em robôs de futebol; os resultados mostraram que ambas as abordagens conseguem rastrear a referência de velocidade, com pequenas ultrapassagens e bom desempenho (Miquelanti *et al.*, 2024). Por fim, algoritmos de programação genética foram explorados para projetar controladores com estrutura matemática explícita, integrando IA ao controle e superando a natureza "caixapreta" de redes neurais (García; Velasco; Angulo; Marti; Camacho, 2023).

Comparativo entre os métodos

Para comparar as estratégias de controle, consideram-se critérios como complexidade de implementação, robustez (capacidade de manter desempenho

sob perturbações e incertezas), custo computacional, flexibilidade (capacidade de adaptação a diferentes condições) e desempenho (tempo de acomodação, *overshoot*, precisão). A Tabela 1 a seguir resume qualitativamente essas características com base nos estudos revisados.

Tabela 1 - Comparativo entre os métodos de controle.

Método	Complexidade de implementação	Robustez	Custo computacional	Desempenho observado
PID clássico	Baixa; requer apenas ajuste de três parâmetros; técnicas como lugar das raízes e Ziegler-Nichols auxiliam na sintonização	Moderada; sensível a variações paramétricas e atrasos	Muito baixo	Bom para sistemas lineares de baixa ordem; <i>overshoot</i> e tempo de acomodação dependem da sintonia
Síntese direta (PI/PID)	Moderada; requer modelo preciso e cálculo da função de transferência desejada	Moderada	Moderado	Consegue resposta não oscilatória em sistemas com atraso
LQR/Estado Espacial	Moderada; exige solução de equações de Riccati e modelagem em espaço de estados	Alta; mantém estabilidade sob perturbações quando combinado com observadores	Moderado	Tempos de acomodação menores e maior robustez comparado a PID.
L1 adaptativo/ MRAC	Alta; envolve derivação de leis de adaptação e filtro de robustez	Alta; separa adaptação e robustez, evitando oscilações	Moderado	Melhora controle de helicópteros e sistemas com incertezas
<i>Gain scheduling</i>	Moderada; exige linearização em vários pontos e interpolação	Moderada	Moderado	Permite rastreamento de velocidade em robôs, com pequenos <i>overshoots</i>
Modo deslizante (SMC)	Moderada; lei de controle composta e seleção de superfície de deslizamento	Muito alta; robusto a perturbações e incertezas	Baixo	<i>Chattering</i> em tempo contínuo; versões discretas reduzem oscilações
<i>Backstepping</i>	Alta; design recursivo e possível complexidade em alta ordem	Alta; permite compensar não linearidades	Moderado a alto	Aplicado em veículos e robôs com boa precisão
Fuzzy e ANFIS	Variável; controladores fuzzy simples exigem definição manual de regras, enquanto ANFIS requer treinamento e dados	Moderada; robusto a incertezas se bem ajustado	Moderado	ANFIS supera fuzzy em precisão e erro
Redes neurais	Alta; treinamento intensivo, arquitetura complexa	Moderada; depende de dados e generalização	Alto	Pode aproximar dinâmicas não modeladas; desempenho variável

Método	Complexidade de implementação	Robustez	Custo computacional	Desempenho observado
Aprendizado por reforço	Alta; requer definição de estado, ação, recompensa e algoritmo de treinamento	Alta; aprende políticas que lidam com incertezas e atrasos	Muito alto; exige processamento intensivo e dados	Reduz erros de rastreamento e melhora eficiência em sistemas em rede

De forma geral, os métodos clássicos destacam-se pela simplicidade e baixo custo, mas apresentam desempenho limitado em sistemas não lineares e com atraso. Os métodos modernos, como LQR, oferecem uma abordagem mais robusta e versátil, mas exigem modelagem precisa e capacidade computacional maior. Estratégias adaptativas ajustam parâmetros em tempo real, sendo úteis em sistemas com variações ou incertezas; no entanto, podem exigir derivação matemática complexa e sintonização de leis de adaptação. Métodos não lineares como o SMC e o *backstepping* fornecem robustez e boa performance em sistemas fortemente não lineares, mas podem sofrer de *chattering* ou complexidade de projeto. Técnicas inteligentes, especialmente aprendizado por reforço, oferecem grande flexibilidade e capacidade de autoajuste, embora seu alto custo computacional e a necessidade de dados possam limitar aplicações em tempo real.

CONCLUSÃO

Esta revisão compilou e comparou as principais estratégias de controle empregadas em automação e robótica no período 2022-2025. Verificouse que, embora o controle clássico (PID, lugar das raízes, Bode) continue presente em inúmeras aplicações devido à simplicidade, suas limitações frente a sistemas com atrasos, não linearidades e incertezas motivam a adoção de métodos modernos e avançados. A representação em espaço de estados e o LQR, aliados a observadores de Kalman, têm mostrado ganhos de desempenho em aplicações veiculares e biomecânicas, proporcionando tempos de acomodação menores e maior robustez (Murugan; Mohamed Ismail, 2025) (Ahmed; Aly; Elhabib, 2025). Controladores adaptativos, como o L1, permitem tratar incertezas sem comprometer a estabilidade, destacando-se em aeronaves de pequeno porte (Bertolani *et al.*, 2024). Técnicas não lineares, especialmente modo deslizante e *backstepping*, oferecem robustez e resposta rápida, porém exigem cuidado

na escolha da superfície de deslizamento e podem sofrer de *chattering* (Latośński; Adamiak, 2024).

Os métodos inteligentes representam uma fronteira promissora: controladores fuzzy e *neurofuzzy* melhoram a flexibilidade, embora dependam de dados de treinamento e possam exigir regras bem definidas (Kern; Marrero; Urrea, 2023). Algoritmos de aprendizado por reforço demonstram potencial para sintonização automática de controladores, redução de erros de rastreamento e adaptação a atrasos e perturbações (Ding *et al.*, 2023) (Chen; Wan; Luan; Liu, 2024). Contudo, a alta demanda computacional e a necessidade de grandes conjuntos de dados limitam sua aplicação imediata em ambientes com restrições de *hardware*. A integração de técnicas híbridas, combinando controladores clássicos ou modernos com algoritmos de IA (por exemplo, LQR com otimização por lobo cinzento, PID com RL, SMC adaptativo), surge como uma tendência que equilibra simplicidade, robustez e capacidade adaptativa. Para sistemas ciberfísicos e Indústria 4.0, onde a integração de sensores, comunicação em rede e tomada de decisão autônoma é essencial, tais abordagens híbridas provavelmente serão fundamentais.

Do ponto de vista de pesquisa, ainda existem lacunas, como a falta de trabalhos recentes que proponham métodos sistemáticos de projeto de lógica fuzzy ou que integrem *backstepping* com aprendizado profundo. De forma semelhante, poucos estudos abordam aplicações em larga escala de controladores fracionários ou comparações quantitativas de custos entre técnicas adaptativas e inteligentes. Esses temas representam oportunidades para investigações futuras. Em conclusão, a escolha da estratégia de controle depende do equilíbrio entre desempenho desejado, complexidade e recursos disponíveis; a literatura recente indica que abordagens que combinam a formalidade matemática dos métodos modernos com a flexibilidade dos algoritmos de inteligência artificial representam um caminho promissor para enfrentar desafios em sistemas complexos e variáveis.

REFERÊNCIAS

AHMED, Khaled; ALY, Ayman A.; ELHABIB, Mohamed O. *Design of Adaptive LQR Control Based on Improved Grey Wolf Optimization for Prosthetic Hand*. *Biomimetics*, Basel, v. 10, n. 7, art. 423, 2025. DOI: 10.3390/biomimetics10070423. Disponível em: <https://www.mdpi.com/2313-7673/10/7/423>. Acesso em: 18 ago. 2025.

AL BAIDHANI, Humam; KAZIMIERCZUK, Marian K. *Design and Implementation of Digital PID Control for Mass Damper Rectilinear Systems*. *Mathematics*, Basel, v. 12, n. 18, art. 2921, 2024. DOI: 10.3390/math12182921. Disponível em: <https://www.mdpi.com/2227-7390/12/18/2921>. Acesso em: 18 ago. 2025.

BARRIOS SÁNCHEZ, J. M.; BAEZA SERRATO, R. *Design and Development of an Optimal Control Model in System Dynamics through State-Space Representation*. *Applied Sciences*, Basel, v. 13, n. 12, art. 7154, 2023. DOI: 10.3390/app13127154. Disponível em: <https://www.mdpi.com/2076-3417/13/12/7154>. Acesso em: 18 ago. 2025.

BERTOLANI, Giulia; RYALS, Andrea Dan; DE ANGELIS, Emanuele Luigi; POLLINI, Lorenzo; GIULIETTI, Fabrizio. *Adaptive Control for Small Scale Unmanned Helicopters: Enhancing Speed Regulation*. *Drones*, Basel, v. 8, n. 11, art. 649, 2024. DOI: 10.3390/drones8110649. Disponível em: <https://www.mdpi.com/2504-446X/8/11/649>. Acesso em: 18 ago. 2025.

CHEN, Wei; WAN, Haiying; LUAN, Xiaoli; LIU, Fei. *Data-Driven Self-Triggered Control for Networked Motor Control Systems Using RNNs and Pre-Training: A Hierarchical Reinforcement Learning Framework*. *Sensors*, Basel, v. 24, n. 6, art. 1986, 2024. DOI: 10.3390/s24061986. Disponível em: <https://www.mdpi.com/1424-8220/24/6/1986>. Acesso em: 18 ago. 2025.

CHOI, D.; KIM, D.; TURNER, J. D. *Optimization of Weight Matrices for the Linear Quadratic Regulator Problem Using Algebraic Closed-Form Solutions*. *Electronics*, Basel, v. 12, n. 21, art. 4526, 2023. DOI: 10.3390/electronics12214526. Disponível em: <https://www.mdpi.com/2079-9292/12/21/4526>. Acesso em: 18 ago. 2025.

DING, Ye; REN, Xiaoguang; ZHANG, Xiaochuan; LIU, Xin; WANG, Xu. *Multi-Phase Focused PID Adaptive Tuning with Reinforcement Learning*. *Electronics*, Basel, v. 12, n. 18, art. 3925, 2023. DOI: 10.3390/electronics12183925. Disponível em: <https://www.mdpi.com/2079-9292/12/18/3925>. Acesso em: 18 ago. 2025.

GARCÍA, Carlos A.; VELASCO, Manel; ANGULO, Cecilio; MARTÍ, Pau; CAMACHO, Antonio. *Revisiting Classical Controller Design and Tuning with Genetic Programming*. *Sensors*, Basel, v. 23, n. 24, art. 9731, 2023. DOI: 10.3390/s23249731. Disponível em: <https://www.mdpi.com/1424-8220/23/24/9731>. Acesso em: 18 ago. 2025.

GILERSON, André; BÜNTE, Niklas; KEHL, Pierre E.; SCHMITT, Robert H. *Adaptive Control Strategies for Networked Systems: A Reinforcement Learning Based Approach*. *Electronics*, Basel, v. 14, n. 7, art. 1312, 2025. DOI: 10.3390/electronics14071312. Disponível em: <https://www.mdpi.com/2079-9292/14/7/1312>. Acesso em: 18 ago. 2025.

KERN, John; MARRERO, Dailin; URREA, Claudio F. *Fuzzy Control Strategies Development for a 3 DoF Robotic Manipulator in Trajectory Tracking*. *Processes*, Basel, v. 11, n. 12, art. 3267, 2023. DOI: 10.3390/pr11123267. Disponível em: <https://www.mdpi.com/2227-9717/11/12/3267>. Acesso em: 18 ago. 2025.

KULA, Krzysztof S. *Tuning a PI/PID Controller with Direct Synthesis to Obtain a Non Oscillatory Response of Time Delayed Systems*. *Applied Sciences*, Basel, v. 14, n. 13, art. 5468, 2024. DOI: 10.3390/app14135468. Disponível em: <https://www.mdpi.com/2076-3417/14/13/5468>. Acesso em: 18 ago. 2025.

LATOSIŃSKI, P.; ADAMIAK, K. *Discrete-Time Sliding Mode Control Strategies — State of the Art. Energies*, Basel, v. 17, n. 18, art. 4564, 2024. DOI: 10.3390/en17184564. Disponível em: <https://www.mdpi.com/1996-1073/17/18/4564>. Acesso em: 18 ago. 2025.

MIQUELANTI, Mateus G.; PUGLIESE, Luiz F.; SILVA, Waner W. A. G.; BRAGA, Rodrigo A. S.; MONTE-MOR, Juliano A. *Comparison between an Adaptive Gain Scheduling Control Strategy and a Fuzzy Multimodel Intelligent Control Applied to the Speed Control of Non-Holonomic Robots. Applied Sciences*, Basel, v. 14, n. 15, art. 6675, 2024. DOI: 10.3390/app14156675. Disponível em: <https://www.mdpi.com/2076-3417/14/15/6675>. Acesso em: 18 ago. 2025.

MURUGAN, Nandhini; MOHAMED ISMAIL, Mohamed Rabik Mohamed. *An Efficient Coordinated Observer LQR Control in a Platoon of Vehicles for Faster Settling Under Disturbances. World Electric Vehicle Journal*, Basel, v. 16, n. 1, art. 28, 2025. DOI: 10.3390/wevj16010028. Disponível em: <https://www.mdpi.com/2032-6653/16/1/28>. Acesso em: 18 ago. 2025.

REN, Zhengru. *A Survey of Modularized Backstepping Control Design Approaches to Nonlinear ODE Systems. arXiv preprint*, arXiv:2305.02066, maio 2023. DOI: 10.48550/arXiv.2305.02066. Disponível em: <https://arxiv.org/abs/2305.02066>. Acesso em: 18 ago. 2025.

ZHANG, Huaqiang; MOHAMAD NOR, Norzalilah. *Control Strategies for Two-Wheeled Self-Balancing Robotic Systems: A Comprehensive Review. Robotics*, Basel, v. 14, n. 8, art. 101, 2025. DOI: 10.3390/robotics14080101. Disponível em: <https://www.mdpi.com/2218-6581/14/8/101>. Acesso em: 18 ago. 2025.

ZHANG, Jinhua; CHEN, Zhenghao; YU, Jinshi. *A Novel Nonlinear Adaptive Control Method for Longitudinal Speed Control for Four-Independent-Wheel Autonomous Vehicles. Mathematics*, Basel, v. 12, n. 22, art. 3509, 2024. DOI: 10.3390/math12223509. Disponível em: <https://www.mdpi.com/2227-7390/12/22/3509>. Acesso em: 18 ago. 2025.

IDENTIFICAÇÃO DE UM PROCESSO COM CARACTERÍSTICA NÃO LINEAR E COMPARAÇÕES DE DESEMPENHO EM RELAÇÃO A UM MODELO NARMAX E UM MODELO COM RNAS

Jorge Lucas Torres Cassaro

Instituto Federal de Educação, Ciência e Tecnologia
do Rio de Janeiro/IFRJ – Campus Volta Redonda

Juliana Ribas Monteiro

Instituto Federal de Educação, Ciência e Tecnologia
do Rio de Janeiro/IFRJ – Campus Volta Redonda

RESUMO

Este trabalho apresenta a modelagem de um processo de nível com característica não-linear. Foram utilizadas duas abordagens distintas: o modelo *NARMAX* (*Nonlinear AutoRegressive Moving Average model with Exogenous inputs*) e uma rede neural artificial do tipo *perceptron* multicamadas. Inicialmente, é feita a identificação do sistema por meio de dados experimentais obtidos de uma planta de tanque único, onde são observadas as não linearidades intrínsecas do processo. Em seguida, realiza-se o treinamento da rede neural com o algoritmo de retropropagação modificado por Levenberg-Marquardt, utilizando uma arquitetura *feedforward* com múltiplas camadas ocultas. Os resultados demonstram a comparação entre os modelos em termos de ajustes e correlação, destacando a eficiência do modelo *NARMAX* para representar a dinâmica não linear e a capacidade da rede neural de generalizar padrões complexos. A validação experimental confirma a viabilidade das técnicas propostas para aplicações em malhas de controle de processos industriais.

Palavras-chave: Modelagem não Linear; Sistema de Nível; Narmax; Rede Neural Artificial.

INTRODUÇÃO

O controle de processos industriais que envolvem variáveis de nível é um tema de grande relevância na engenharia de controle e automação, dado que sistemas de tanque estão presentes em diversas plantas químicas, petroquímicas, saneamento e outras aplicações industriais. A capacidade de manter níveis estáveis em reservatórios é fundamental para garantir a segurança operacional, qualidade do produto e eficiência energética. Nesse contexto, a modelagem precisa do sistema e a escolha de estratégias de controle adequadas são etapas essenciais para o sucesso da operação (OGATA,2010), (ASTROM,2021).

Sistemas reais, como sistemas de nível, frequentemente apresentam características não lineares, zonas mortas, histereses, atrasos e outras incertezas que dificultam a obtenção de modelos precisos por abordagens puramente lineares. Diante deste cenário, técnicas de modelagem não linear, como o modelo NARMAX, tem se mostrado ferramentas eficazes para representar sistemas reais de forma mais fidedigna (BILLINGS,2013).

O modelo NARMAX é amplamente reconhecido por sua flexibilidade na representação de sistemas não lineares e por permitir a inclusão de informações de entradas e saídas passadas, bem como termos de ruídos. Esse tipo de abordagem é aplicado com sucesso em diferentes áreas, como sistemas mecânicos, processos químicos, redes elétricas e plantas didáticas de nível (CHEN,1989), (NARENDRA,1989). Ao considerar as não linearidades intrínsecas ao processo, o modelo NARMAX contribui para um melhor desempenho das estratégias de controle, principalmente quando combinado com técnicas de identificação de parâmetros e validação experimental.

Paralelamente aos modelos matemáticos, a aplicação de redes neurais artificiais tem ganhado destaque como alternativa poderosa para a modelagem de sistemas complexos. As redes neurais, por sua natureza de aprendizado, podem capturar relações altamente não lineares entre variáveis de processo, dispensando a necessidade de conhecimento aprofundado da dinâmica interna do sistema (HAYKIN,2009). Diversos estudos demonstram que redes neurais podem não somente modelar com precisão plantas de nível, mas também atuar como controladores inteligentes, adaptando-se a mudanças nas condições operacionais e incertezas do ambiente (NARENDRA,1989), (SIMPKINS,2012).


Neste trabalho, propõe-se a modelagem de uma planta didática de nível por meio de duas abordagens distintas: o modelo *NARMAX*, obtido a partir de dados experimentais, e uma *RNA* do tipo *perceptron* de multicamadas treinada com algoritmos de retro propagação. A comparação entre as duas abordagens permite avaliar o desempenho, robustez e capacidade de generalização de cada modelo.

A utilização de uma planta didática de nível neste trabalho possibilita a validação prática dos métodos estudados em um ambiente controlado. Assim, demonstra-se a viabilidade da aplicação de técnicas avançadas de modelagem e controle em sistemas reais.

PLANTA DIDÁTICA DE UM SISTEMA DE NÍVEL

O sistema escolhido, conforme apresentado na Figura 1 foi proposto com base no conhecido sistema de Quatro Tanques, criado por (JOHANSSON,2002). No entanto, diferentemente do sistema de múltiplos tanques, este sistema foi desenvolvido para fornecer estudos sobre a modelagem e o controle de um sistema de Entrada Única e Saída Única (SISO).

Figura 1. O esquema de tanque único.




A Figura. 1 apresenta o diagrama do sistema, cujo principal desafio está na complexidade de definir a dinâmica do nível de água no Tanque 1 em resposta a ações específicas da bomba 1 e determinar as ações para a bomba 1 a fim de manter ou atingir um nível de água específico.

Planta Física

A configuração do sistema físico construído está ilustrada na Figura. 2. Este protótipo é composto por um sensor de pressão diferencial, uma eletrobomba automotiva, uma plataforma de microcontrolador de fácil acesso e diversos materiais que compõem a estrutura, as conexões e os reservatórios. Informações adicionais sobre o sistema podem ser encontradas nas Tabelas 1 e 2.

Figura 2. Ilustração da planta do sistema de nível.



As Tabelas 1 e 2 apresentam os principais componentes utilizados na construção da planta didática de nível, bem como os materiais e dimensões adotados para sua estrutura física. A Tabela 1 descreve os elementos funcionais do sistema, como o sensor de pressão diferencial HX710B, responsável pela medição do nível, a eletrobomba automotiva que atua como atuador do processo, o microcontrolador Arduino Nano e a fonte de alimentação em corrente contínua.

Tabela 1. Sistema de Nível: principais componentes e funções.

Elemento	Descrição
Sensor de pressão	HX710B (0 a 40KPa)
Atuador	Eletro-bomba de carro
Microcontrolador	Arduino Nano
Alimentação	DC (12V /5A)
Interface	Circuito MOSFET

Já a Tabela 2 detalha os materiais de construção, destacando o uso de acrílico para os tanques superior e auxiliar, além de MDF para a base e a coluna de sustentação. Esses dados evidenciam a escolha de materiais acessíveis e de fácil manipulação, garantindo baixo custo e praticidade na montagem, sem comprometer a robustez e a representatividade experimental do protótipo.


Tabela 2. Sistema de Nível: Tanque e Material.

Elemento	Material	Dimensões Principais
Tanque Superior	Acrílico	10 [cm] x 15 [cm] x 08 [cm]
Tanque Auxiliar	Acrílico	10 [cm] x 10 [cm] x 10 [cm]
Base	MDF	15 [cm] x 30[cm]
Coluna	MDF	15 [cm] x 30[cm]

Análise de Não Linearidades

Para examinar as características não lineares do sistema de nível (NETO,2024), foram implementadas excitações da bomba em malha aberta. Estas assumiram a forma de entradas em degrau com valores constantes variando de 40 PWM a 160 PWM de Modulação por Largura de Pulso (PWM) (ver Figura. 3).

Figura 3. Sistema de Nível: Resposta ao degrau.



MODELO NARMAX

O modelo NARMAX (*Nonlinear AutoRegressive Moving Average model with Exogenous inputs*) é uma das abordagens mais utilizadas para modelagem de sistemas dinâmicos não lineares. Sua principal característica é a capacidade de representar de forma explícita a estrutura não linear do sistema, considerando em consideração não somente entradas e saídas passadas, mas também erros anteriores do modelo (BILLINGS,2013).

Diferente de modelos lineares como ARX (*AutoRegressive with Exogenous*) ou ARMAX (*AutoRegressive Moving Average with exogenous inputs*), o NARMAX permite a inclusão de termos não lineares na regressão, o que possibilita capturar efeitos complexos e interações entre variáveis (LEONTARITIS,1985). Por isso, ele é amplamente empregado em áreas como identificação de sistemas, controle adaptativo e previsão de séries temporais (CHEN,1989).

A formulação básica do modelo pode ser expressa como:

$$y(t) = F(y(t-1), \dots, y(t-ny), u(t-1), \dots, u(t-nu), e(t-1), \dots, e(t-ne)) + e(t) \quad (1)$$

Onde $y(t)$ é a saída, $u(t)$ é a entrada, $e(t)$ é o termo de erro e $F(\cdot)$ representa uma função não linear (CHEN,1989).

O sucesso do NARMAX deve-se também a variedade de métodos desenvolvidos para estimar os seus parâmetros, como o algoritmo de expansão em séries de Volterra ou a utilização de redes neurais para representar a função não linear F (NELLES,2002).

Dentre as principais vantagens do modelo NARMAX, destacam-se:

1. Flexibilidade para modelar dinâmicas fortemente não lineares;
2. Capacidade de representar a dinâmica interna e a influência de entradas externas;
3. Facilidade de implementação computacional com ferramentas de identificação

Assim, o modelo NARMAX continua sendo uma ferramenta poderosa para engenheiros e pesquisadores que necessitam representar sistemas reais com alta precisão, mesmo quando a dinâmica do processo é complexa e não linear (CHEN,1989).

REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano, capazes de aprender padrões complexos e generalizar informações a partir de dados. Desde as primeiras concepções matemáticas, as RNAs tornaram-se ferramentas centrais em tarefas de reconhecimento de padrões, classificação, regressão e previsão (HAYKIN,2009), (GOODFELLOW,2016).

A ideia fundamental é similar ao comportamento de neurônios biológicos, em uma RNA, unidades chamadas neurônios artificiais são interligadas por pesos sinápticos, que ajustam a intensidade da informação transmitida. Essa estrutura permite que as redes aprendam a partir de exemplos e se adaptem a novos contextos sem regras explícitas (RUMELHART,1986).

Fundamentos Teóricos

Uma rede neural típica é composta por camadas: entrada, ocultas e saída. O *perceptron* multicamadas (MLP) é uma das arquiteturas mais conhecidas, usados para problemas não linearmente separáveis (ROSENBLATT,1958), (HORNIK,1989).

O treinamento ajusta pesos para minimizar uma função de erro, usando o algoritmo de retropropagação do erro (*back propagation*) (RUMELHART,1986).

Outras arquiteturas incluem redes convolucionais (CNNs) para imagens (LECUN,2002), redes recorrentes (RNNs) para séries temporais (HOCHREITER,1998) e autoencoders para redução de dimensionalidade.

RESULTADOS EXPERIMENTAIS

Rede Neural utilizada

Foi utilizada uma rede neural com arquitetura *feed forward* com camadas múltiplas constituindo um *perceptron* multicamadas. A arquitetura com realimentação foi escolhida de forma que ela é utilizada para obter a relação do nível conforme o tempo e o percentual de abertura da válvula. Para o treinamento da rede, foi utilizado o algoritmo de aprendizado *backpropagation* modificado por Levenberg –Maquardt e a função de ativação da rede escolhida foi a logística. A rede possui três entradas e uma saída.

É importante determinar a quantidade de camadas intermediárias, a quantidade de neurônios na rede. Com duas camadas intermediárias é possível aproximar qualquer função matemática e ainda classificar padrões que estejam em quaisquer tipos de regiões geométricas (LIPMAN,1987). Foram testadas algumas configurações determinada uma rede com 15 neurônios na primeira camada intermediária e 10 na segunda camada.


A partir do treinamento supervisionado adotado considera-se a abertura da válvula $y(n)$ e o nível de água $x(n)$ obtendo assim uma relação entre as entradas e as saídas desejadas.

Treinamento e Validação

A Figura 4 apresenta a arquitetura da rede neural desenvolvida para modelar o comportamento dinâmico da planta de nível. Observa-se que a rede possui múltiplas camadas ocultas, configuradas de forma a permitir a aproximação de funções altamente não lineares, o que é essencial diante das características intrínsecas do sistema em análise. O modelo adotado segue a estrutura *feedforward*, onde os sinais fluem da entrada até a saída sem realimentação

interna, exceto pelo mecanismo de treinamento supervisionado. Essa escolha visa garantir estabilidade e eficiência durante o processo de aprendizado.

Figura 4. Rede Neural.




A definição da quantidade de neurônios em cada camada intermediária é um ponto crucial, pois impacta diretamente a capacidade de generalização do modelo. No caso em estudo, foram utilizados 15 neurônios na primeira camada intermediária e 10 na segunda, configuração que mostrou bom equilíbrio entre desempenho e custo computacional. Essa topologia foi escolhida com base em testes empíricos, de forma a minimizar o erro de treinamento sem incorrer em sobreajuste. A Figura 4 ilustra claramente como cada entrada é processada sucessivamente até gerar a saída desejada, representando o nível do tanque em função das ações de controle.

Além disso, nota-se que o emprego de funções de ativação logísticas e tangenciais permite à rede capturar comportamentos não lineares de forma eficiente. Esse aspecto é especialmente relevante, considerando que a planta de nível apresenta histerese e atrasos dinâmicos que não podem ser adequadamente representados por modelos lineares. Assim, a Figura 4 sintetiza a estrutura fundamental do modelo neural, evidenciando a sua capacidade de aprender e representar relações complexas entre variáveis de entrada e saída.

A Figura 5 abaixo, exibe o processo de treinamento da rede neural, realizado com o algoritmo de retropropagação modificado por Levenberg-Marquardt. Esse método é amplamente utilizado devido à sua rápida convergência e eficácia em problemas de ajuste de funções não lineares. O gráfico mostra a evolução do erro ao longo das iterações, destacando a forma como a rede ajusta seus pesos sinápticos para minimizar a diferença entre as saídas previstas e as saídas reais do sistema.

Figura 5. Treinamento.




É possível observar que, à medida que o treinamento avança, o erro decai gradualmente até atingir um patamar estável, indicando que a rede conseguiu capturar adequadamente os padrões existentes nos dados experimentais. Esse comportamento confirma que a escolha da arquitetura e do algoritmo de treinamento foi adequada para o problema em questão. A estabilização do erro em valores reduzidos é uma forte evidência da capacidade do modelo de generalizar sem perder precisão.

Outro ponto importante é que o treinamento foi realizado com um conjunto de 1200 amostras, quantidade suficiente para representar adequadamente a dinâmica do processo. A Figura 5 demonstra, portanto, não apenas o sucesso do treinamento, mas também a robustez do modelo ao lidar com dados reais e não lineares. Isso é fundamental para garantir que a rede neural seja confiável em aplicações práticas de controle.

A Figura 6 mostra o resultado da regressão obtida pela rede neural, comparando as saídas previstas com as saídas reais do sistema. O gráfico evidencia um forte alinhamento entre os dois conjuntos de dados, o que se traduz em um coeficiente de correlação elevado (superior a 0,99, conforme discutido na análise). Esse resultado confirma a eficiência do modelo neural em reproduzir a dinâmica da planta de nível com alta precisão.

Figura 6. Regressão.




Visualmente, é possível perceber que os pontos da regressão estão concentrados próximos da reta ideal de correlação, indicando que os erros residuais são pequenos e distribuídos de forma aleatória. Isso significa que a rede não apenas ajustou os dados de treinamento, mas também foi capaz de aprender o padrão subjacente do sistema. Tal característica é essencial em problemas de controle, onde a generalização é tão importante quanto o ajuste do modelo.

Além disso, a Figura 6 evidencia a vantagem das redes neurais na modelagem de sistemas não lineares, quando comparadas a abordagens tradicionais. A capacidade de capturar relações complexas sem necessidade de equações explícitas demonstra a flexibilidade e a aplicabilidade do modelo

em diferentes condições operacionais. Portanto, a regressão apresentada na Figura 6 confirma o sucesso da etapa de treinamento e valida o uso da rede neural na modelagem proposta.

A Figura 7 apresenta o histograma dos erros de predição obtidos pela rede neural, o que permite analisar a distribuição das diferenças entre os valores reais e os valores estimados pelo modelo. Nota-se que a maior parte dos erros se concentra próxima de zero, evidenciando que a rede neural conseguiu capturar a dinâmica do sistema com elevada acurácia. Essa característica indica que não há viés significativo no modelo, reforçando sua confiabilidade.

Figura 7. Histograma.



A distribuição de erros relativamente simétrica e concentrada em torno do valor nulo demonstra que os desvios são pequenos e não sistemáticos. Isso é fundamental em modelagem, pois garante que o modelo não privilegie determinadas condições em detrimento de outras. Caso houvesse caudas alongadas ou concentração de erros em faixas específicas, seria um indicativo de sobre ajuste ou de deficiência na arquitetura da rede.

Assim, a Figura 7 cumpre o papel de validar estatisticamente a qualidade do modelo neural. Ela mostra que, além de apresentar bom desempenho em termos de correlação, o modelo mantém erros distribuídos de maneira adequada, sem tendências. Essa evidência fortalece a conclusão de que a

rede neural é uma ferramenta robusta e eficiente para representar sistemas de nível não lineares.

Estimação do modelo da Rede Neural

$$Y = LW \cdot \tanh(IW \cdot X + b_1) + b_2 \quad (2)$$

$$\begin{aligned} Y = & -0.0932 \cdot \text{tansig}(14.0582 \cdot X - 13.9391) \\ & + 0.1805 \cdot \text{tansig}(13.5498 \cdot X - 11.4222) \\ & - 0.1058 \cdot \text{tansig}(-13.8574 \cdot X + 7.9718) \\ & + 0.1085 \cdot \text{tansig}(14.0005 \cdot X - 4.6657) \\ & + 0.1348 \cdot \text{tansig}(14.0001 \cdot X - 1.5385) \\ & - 0.1586 \cdot \text{tansig}(-14.0042 \cdot X - 1.4865) \\ & - 0.1397 \cdot \text{tansig}(-13.9938 \cdot X - 4.6957) \\ & + 0.1193 \cdot \text{tansig}(14.0031 \cdot X + 7.7500) \\ & + 0.0631 \cdot \text{tansig}(14.0657 \cdot X + 10.8102) \\ & + 0.0457 \cdot \text{tansig}(13.8281 \cdot X + 14.1709) \\ & - 0.0987 \end{aligned}$$

As Tabelas 4, 5 e 6 apresentam os parâmetros relacionados à rede neural artificial utilizada na modelagem do sistema de nível. A Tabela 4 mostra os pesos de entrada (IW), responsáveis por determinar a intensidade da influência das variáveis de entrada sobre os neurônios da primeira camada oculta.

Tabela 4. Pesos de Entrada (IW).

Neurônio	Peso(IW)
1	14.0582
2	13.5498
3	13.8574
4	14.0005
5	14.0001
6	14.0042
7	-13.9938
8	14.0031
9	14.0657
10	13.8281

Já a Tabela 5 descreve os pesos da camada oculta para a saída (LW), evidenciando como cada neurônio contribui para a resposta final da rede, com valores positivos e negativos que refletem a capacidade de ajuste do modelo às dinâmicas não lineares.

Tabela 5. Pesos da camada oculta para a saída (LW).

Neurônio	Peso(LW)
1	-0.0932
2	0.1805
3	-0.1058
4	0.1085
5	0.1348
6	-0.1586 7
7	-0.1397
8	0.1193
9	0.0631
10	0.0457

A Tabela 6, por sua vez, traz as baías da camada oculta (b1), que representam deslocamentos aplicados à função de ativação de cada neurônio. Esses valores são essenciais para permitir que a rede neural consiga capturar padrões complexos e corrigir desvios que não poderiam ser ajustados apenas pelos pesos sinápticos.

Tabela 6. Baías da camada Oculta (b1).

Neurônio	Baías b1
1	13.9391
2	11.4222
3	7.9718
4	-4.6657
5	-1.5385
6	1.4865
7	-4.6957
8	7.7500
9	10.8102
10	14.1709

Estimação do modelo NARMAX

$$y(k) = 0.853200 y(k-1) - 0.214500 y(k-2) + 0.432700 u(k-1) + 0.189200 u(k-2) + F_NL + e(k) \quad (3)$$

As Tabelas 7 e 8 apresentam os parâmetros do modelo NARMAX estimado para a mesma planta de nível. A Tabela 7 reúne os coeficientes associados às saídas passadas do sistema, mostrando a memória do processo e como os estados anteriores influenciam a resposta atual.

Tabela 7. Parâmetros de saída estimado do modelo NARMAX.

Parâmetros estimados	Parâmetros da saída (A)
a1	0.853200
a2	-0.214500


Já a Tabela 8 mostra os coeficientes relacionados às entradas passadas, que quantificam de forma explícita o impacto dos sinais de excitação na evolução do sistema. A análise conjunta dessas tabelas permite verificar que o modelo NARMAX, ao contrário da rede neural, possui uma formulação matemática mais transparente e interpretável, o que facilita a compreensão das relações dinâmicas.

Tabela 8. Parâmetros de entrada estimado do modelo NARMAX.

Parâmetros estimados	Parâmetros da entrada (B)
b1	0.432700
b2	- 0.189200

A Figura 8 ilustra a estrutura do modelo NARMAX aplicado à planta de nível, destacando a forma como entradas, saídas passadas e termos não lineares são incorporados na modelagem. Esse tipo de representação é especialmente útil, pois permite compreender visualmente como o modelo captura as interações dinâmicas entre variáveis, incluindo efeitos de ordem superior que não poderiam ser descritos apenas por regressões lineares.

Figura 8. Narmax.




O modelo NARMAX utiliza coeficientes específicos para as entradas e saídas passadas, além de termos adicionais que representam as não linearidades do processo. Essa característica torna o modelo bastante flexível e capaz de representar a dinâmica real do sistema com alta fidelidade. Na Figura, observa-se como os diferentes termos contribuem para a composição da saída estimada, refletindo tanto a influência imediata das entradas quanto a memória do sistema.

Essa abordagem se diferencia das redes neurais por apresentar uma estrutura matemática mais explícita e interpretável, o que pode ser uma vantagem em algumas aplicações industriais. A Figura 8, portanto, sintetiza a robustez do modelo NARMAX, evidenciando seu potencial como ferramenta de identificação e controle em sistemas não lineares.

A Figura 9 apresenta a resposta do modelo NARMAX em comparação aos dados experimentais, mostrando o quão próximo o modelo foi capaz de reproduzir o comportamento real da planta de nível. Nota-se uma forte sobreposição entre as curvas, indicando elevada precisão na estimativa da saída do sistema. Esse resultado é consistente com o elevado coeficiente de correlação obtido (0,9993), demonstrando a eficácia da abordagem.

Figura 9. Resposta.



O alinhamento entre os valores simulados e os valores experimentais confirma que o modelo NARMAX é capaz de capturar adequadamente as não linearidades presentes na planta. Além disso, observa-se que o modelo

responde de maneira rápida e precisa a variações de entrada, o que é um requisito fundamental em aplicações de controle em tempo real. Essa fidelidade garante confiabilidade em cenários práticos, onde atrasos ou desvios podem comprometer a estabilidade do sistema.

Outro aspecto importante é que a resposta do modelo se manteve estável e coerente ao longo de toda a série temporal, sem apresentar oscilações espúrias ou desvios acumulativos. Isso evidencia que a estrutura matemática escolhida foi adequada e que os parâmetros foram estimados corretamente. Dessa forma, a Figura 9 reforça a conclusão de que o NARMAX é uma alternativa extremamente eficaz para modelagem de sistemas de nível não lineares.

CONCLUSÃO

Os resultados obtidos comprovam que tanto o modelo NARMAX quanto a rede neural *perceptron* multicamadas conseguem modelar com precisão a planta didática de nível, considerando as não linearidades. O NARMAX destacou-se por sua robustez e simplicidade de implementação para sistemas dinâmicos não lineares, enquanto a rede neural apresentou excelente capacidade de aprendizado e generalização, mesmo para padrões complexos. Assim, conclui-se que ambas as abordagens são viáveis para aplicações em processos industriais, podendo ser utilizadas complementarmente, conforme as características e requisitos de cada sistema.

REFERÊNCIAS

OGATA, Katsuhiko. *Modern control engineering*. Prentice Hall, 2010.

ÅSTRÖM, Karl Johan; MURRAY, Richard. *Feedback systems: an introduction for scientists and engineers*. Princeton University Press, 2021.

BILLINGS, Stephen A. *Nonlinear system identification: NARMAX methods in the time, frequency, and spatio-temporal domains*. John Wiley & Sons, 2013.

CHEN, Sheng; BILLINGS, Steve A. Representations of non-linear systems: the NARMAX model. *International Journal of Control*, v. 49, n. 3, p. 1013-1032, 1989.

- NARENDRA, K. S. Identification and control of dynamical systems using neural networks. **IEEE Transactions on Neural Networks**, v. 1, n. 1, p. 183-192, 1989.
- HAYKIN, Simon. *Neural networks and learning machines*. 3. ed. Pearson Education India, 2009.
- SIMPKINS, Alex. System identification: Theory for the user, (Ijung, I.; 1999)[on the shelf]. **IEEE Robotics & Automation Magazine**, v. 19, n. 2, p. 95-96, 2012.
- JOHANSSON, Karl Henrik. The quadruple-tank process: A multivariable laboratory process with an adjustable zero. **IEEE Transactions on Control Systems Technology**, v. 8, n. 3, p. 456-465, 2002.
- LEONTARITIS, I. J.; BILLINGS, Stephen A. Input-output parametric models for non-linear systems part I: deterministic non-linear systems. **International Journal of Control**, v. 41, n. 2, p. 303-328, 1985.
- NELLES, Oliver. Nonlinear system identification. *Measurement Science and Technology*, v. 13, n. 4, p. 646-646, 2002.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. *Deep learning*. Cambridge: MIT Press, 2016.
- RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **Nature**, v. 323, n. 6088, p. 533-536, 1986.
- HOCHREITER, Sepp. Recurrent neural net learning and vanishing gradient. **International Journal Of Uncertainty, Fuzziness and Knowledge-Based Systems**, v. 6, n. 2, p. 107-116, 1998.
- ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, v. 65, n. 6, p. 386-408, 1958.
- HORNIK, Kurt; STINCHCOMBE, Maxwell; WHITE, Halbert. Multilayer feedforward networks are universal approximators. **Neural Networks**, v. 2, n. 5, p. 359-366, 1989.
- LECUN, Yann; BOTTOU, Léon; BENGIO, Yoshua; HAFFNER, Patrick. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, v. 86, n. 11, p. 2278-2324, 2002.
- LIPMAN, Peter W.; BANKS, Norman G. AA flow dynamics, Mauna Loa 1984. *US Geological Survey Professional Paper*, v. 1350, p. 1527-1567, 1987.
- NETO, A. F. D. S.; CASSARO, J. L. T.; DOS SANTOS, M. F.; SCHETTINO, V. B.; MERCORELLI, P. Gain scheduling controller for improving level control performance. In: INTERNATIONAL CARPATHIAN CONTROL CONFERENCE (ICCC), 25., 2024, [S.l.]. *Proceedings.... IEEE*, 2024. p. 1-6.

SOBRE OS ORGANIZADORES

Leonardo de Carvalho Vidal

Atualmente é professor efetivo (DE) *Campus* Volta Redonda e Coordenador do Curso de Pós Graduação em Automação Industrial e Robótica do IFRJ- Instituto Federal do Rio de Janeiro. Docente permanente do Programa de Pós-Graduação em Montagem Industrial da Universidade Federal Fluminense .Doutorado em Engenharia Elétrica da UNIFEI, Engenheiro Eletricista com Mestrado em Engenharia Mecânica com área de concentração em Automação. Atuou como Coordenador do NUPIDE - Centro de Pesquisa, Inovação e Difusão das Engenharias do Centro Universitário de Barra Mansa, Coordenador do Curso de Pós Graduação em Automação e Robótica do Centro Universitário de Barra Mansa , professor da Associação Educacional Dom Bosco - Resende/RJ e da Centro Universitário de Barra Mansa. Atuou como professor substituto da UERJ - Universidade Estadual do Rio de Janeiro - Resende/RJ. Atuou como Diretor Executivo do SAAE -VR - Serviço Autônomo de Água e Esgoto de Volta Redonda; Atuou como Coordenador de Projetos na MICHELIN.

Lattes: <http://lattes.cnpq.br/2401543076073435>

Gilmar Gonçalves de Oliveira

Mestre em Desenvolvimento de Tecnologia pelo IEP/Lactec-PR (2007), graduado em Engenharia Eletr. Eletrônica - Faculdades Reunidas Nuno Lisboa (1991). Atualmente exerce a função de professor DE (Automação, Instrumentação, Redes e Sistemas Supervisórios e Internet das Coisas) no Instituto Federal do Rio de Janeiro (IFRJ), *campus* de Volta Redonda - RJ.Membro do Núcleo de Inovação e Tecnologia do IFRJ (NiTEC - *campus* Volta Redonda/RJ) desde 30/09/2019 (IN 28/2019). Representante do NiTEC junto ao Centro Tecnológico do Sul Fluminense (CTSF).

Lattes: <http://lattes.cnpq.br/9619588064949206>

Juliana Ribas Monteiro

Bacharela em Engenharia Elétrica pela Faculdade de Engenharia de Resende (2013), Mestra em Ciências em Engenharia Elétrica (Sistemas de Controle, 2015) e Doutora em Ciências em Engenharia Elétrica (Redes Inteligentes, 2020) pela Universidade Federal de Itajubá. Atualmete é Professora no Instituto Federal de Educação Ciência e Tecnologia do Rio de Janeiro (IFRJ), *campus* Volta Redonda. Seus interesses de pesquisa incluem redes inteligentes, sistemas de controle,

modelagem de sistemas dinâmicos não-lineares e inteligência artificial.

Lattes: <http://lattes.cnpq.br/2652393084193388>

Wallace Pereira Neves dos Reis

Possui graduação em Engenharia Elétrica com ênfase em Eletrônica, Licenciatura em Matemática, Especialização em Novas Tecnologias Educacionais, Mestrado em Engenharia Elétrica pela Universidade Federal de Itajubá - UNIFEI e Doutorado em Ciência da Computação pela Universidade Federal de São Carlos - UFSCar, linha de pesquisa Inteligência Artificial, na área de Automação Industrial. É Professor do Ensino Básico Técnico e Tecnológico do Instituto Federal de Educação, Ciência e Tecnologia do Rio de Janeiro, IFRJ - *Campus* Volta Redonda, desde 2014, atuando, principalmente, nos cursos técnicos em Eletrotécnica e Automação Industrial. Tem experiência na área de Sistemas de Controle, Sistemas Multirrobo, Eletrônica Embarcada, Processamento de Imagens, Robótica Educacional. Seus interesses de pesquisa atuais são Despacho de AGVs, Design de Controle de Posição de AGVs, Sistemas Embarcados, Inteligência Artificial aplicada à Sistemas de Controle.

Lattes: <http://lattes.cnpq.br/5790520582500572>

ÍNDICE REMISSIVO

A

Aplicação: 9, 12, 14, 23, 25, 28, 29, 30, 31, 33, 35, 37, 41, 45, 55, 65, 71, 87, 102, 106, 107, 122, 24, 26, 32, 39, 42, 43, 44, 47, 54, 55, 57, 76, 79, 81, 82, 84, 85, 96

Artificial Intelligence: 24, 30, 38, 39, 40

Automação Elétrica: 42, 49

B

Baterias: 20, 21, 22, 23, 25, 26, 27, 28, 33, 37, 38, 39

BMS: 21, 26

C

Cabeçote Galvanométrico: 2

Câmera Térmica: 96, 100, 103, 108, 117, 120, 121, 124

Cinemática Direta: 68, 69, 71, 72, 73, 75, 93

Cinemática Inversa: 69, 70, 71, 75, 77, 79, 84, 93

Controle Adaptativo: 55, 66, 67, 14, 81, 82, 87, 88

Controle em Espaço de Estados: 44, 66

Controle Inteligente: 81, 82, 91

Controle não-Linear: 81

E

Eficiência Energética: 96, 98, 99, 125

Energia Solar: 96, 97, 105, 125, 126, 78

F

Fuzzy: 21, 22, 23, 24, 33, 34, 35, 36, 37, 38, 39, 40, 56, 57, 58, 59, 60, 61, 63, 64, 65, 66, 67, 69, 70, 72, 73, 74, 75, 76, 77, 78, 79, 81, 82, 83, 84, 88, 89, 91, 92, 93, 94, 96, 97, 98

G

Galvo: 2, 17, 19

Gravação a Laser: 2

I

Identificação de Sistemas: 44, 55, 57, 66

IEC 61850: 41, 42, 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 54, 55

Infraestrutura Energética: 42

Inteligência Artificial: 8, 10, 12, 22, 26, 27, 30,

35, 37, 41, 96, 98, 99, 101, 102, 108, 117, 124, 125, 20, 21, 22, 23, 58, 59, 76, 79, 91, 96

Inteligência Artificial: 8, 10, 12, 22, 26, 27, 30, 35, 37, 41, 96, 98, 99, 101, 102, 108, 117, 124, 125, 20, 21, 22, 23, 58, 59, 76, 79, 91, 96

M

Machine Learning: 25, 26, 27, 29, 30, 33, 35, 37, 38, 40, 41, 42, 125

Microusinagem a Laser: 2, 16

Modelo Fuzzy: 33, 36, 38, 39, 56, 57, 58, 60, 64, 65, 69, 70, 73, 74, 76, 77

O

on-the-fly: 2, 3, 11, 12, 13, 16, 17, 18, 19

P

Predictive Maintenance: 30, 38, 39, 40, 41, 42

Previsibilidade: 8, 9, 10, 20, 22, 23, 32, 33, 34

Produção: 8, 9, 10, 11, 15, 18, 19, 20, 21, 22, 23, 39, 71, 123, 54

Q

Quadrirrotor: 43, 44, 45, 46, 47, 48, 49, 50, 51, 52, 55, 57, 65, 66, 67

Qualidade da Água: 56, 57, 59, 60, 61, 62, 63, 66, 69, 73, 74, 75, 76, 77, 78, 79

R

Rede Neural: 95, 96, 100, 108, 110, 111, 112, 114, 120, 126, 30, 31, 32

Redes Neurais Artificiais: 21, 23, 25, 26, 27, 38, 82, 91, 92

Riscos Técnicos: 42

Robô IRB ABB 1010: 69

Rolling Mill: 30, 38, 39, 41

S

Servossistema do Tipo 1: 44, 59

Simulação: 18, 19, 20, 38, 46, 55, 66, 68, 69, 71, 92, 93, 94, 36, 37, 48, 49, 53, 57, 61, 66, 87

Simulação Computacional: 69, 71, 48, 57, 66

Steel Industry: 30, 39, 41

Subestações Digitais: 41, 42, 43, 44, 45, 46, 47, 50, 52, 54, 55

Sustentabilidade: 9, 10, 21, 22, 23, 125, 126, 54, 77

V

Viabilidade de Investimento: 9, 10, 22



científica digital



VENDA PROIBIDA - ACESSO LIVRE - OPEN ACCESS



www.cientificadigital.org | contato@cientificadigital.org